

VYSOKÁ ŠKOLA BÁŇSKÁ – TECHNICKÁ UNIVERZITA OSTRAVA
EKONOMICKÁ FAKULTA

KATEDRA FINANCÍ

Zhodnocení vlivu vybraných faktorů na výkonnost environmentálních aktiv
Evaluation of the Influence of Selected Factors on the Performance of Environmental
Assets

Student: Bc. Nikola Ličková
Vedoucí diplomové práce: Ing. Martina Novotná, Ph.D.

Ostrava 2020

VŠB - Technická univerzita Ostrava
Ekonomická fakulta
Katedra financí

Zadání diplomové práce

Student: **Bc. Nikola Ličková**
Studijní program: N6202 Hospodářská politika a správa
Studijní obor: 6202T010 Finance
Téma: **Zhodnocení vlivu vybraných faktorů na výkonnost environmentálních aktiv**
Evaluation of the Influence of Selected Factors on the Performance of Environmental Assets
Jazyk vypracování: čeština

Zásady pro vypracování:

1. Úvod
 2. Charakteristika environmentálních aktiv
 3. Popis metody lineární regresní analýzy
 4. Zhodnocení vlivu vybraných faktorů na akciové environmentální indexy
 5. Závěr
- Seznam použité literatury
Seznam zkratk
Prohlášení o využití výsledků diplomové práce
Seznam příloh
Přílohy

Seznam doporučené odborné literatury:

CIPRA, Tomáš. *Finanční ekonometrie*. 2. vyd. Praha: Ekopress, 2013. ISBN 978-80-86929-93-4.
SANDOR, Richard et al. *Environmental markets: a new asset class*. United States: CFA Institute Research Foundation, 2014. ISBN 978-1-934667-66-8.
VESELÁ, Jitka. *Investování na kapitálových trzích*. 3. vyd. Praha: Wolters Kluwer, 2019. ISBN 978-80-7598-212-4.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Martina Novotná, Ph.D.**

Datum zadání: 22.11.2019

Datum odevzdání: 24.04.2020




Ing. Iveta Ratmanová, Ph.D.
vedoucí katedry

doc. Ing. Lenka Kauerová, CSc.
proděškanka pro studium
na základě pověření k jednání č.j.
VSB/19/050319/9900 ze dne 24. 9. 2019

Prohlašuji, že jsem celou diplomovou práci, včetně všech příloh, vypracovala samostatně.

V Ostravě dne 24. 12. 2020


.....

Bc. Nikola Ličková

Tímto bych velice ráda poděkovala vedoucí mé diplomové práce paní Ing. Martině Novotné, Ph.D, za cenné rady, odbornou pomoc a v neposlední řadě za vstřícnost a ochotu při konzultacích.

Obsah

1	Úvod.....	6
2	Charakteristika environmentálních aktiv	8
2.1	Akciové indexy	8
2.1.1	S&P Dow Jones Indices LLC	11
2.1.2	S&P Global Water Index	11
2.1.3	S&P Global Clean Energy Index	12
2.1.4	S&P Global Eco Index.....	13
2.2	Vybrané faktory charakterizující životní prostředí	14
2.2.1	Koncentrace oxidu uhličitého v atmosféře	14
2.2.2	Koncentrace metanu v atmosféře.....	17
2.2.3	Objem prodeje elektromobilů a plug-in hybridů	19
2.2.4	Podíl energie z obnovitelných zdrojů v zemích OECD	21
3	Popis metody lineární regrese	24
3.1	Ekonometrie	24
3.2	Formulace modelu.....	24
3.3	Sběr a analýza dat.....	25
3.4	Odhad parametrů modelu	27
3.5	Verifikace modelu	30
3.5.1	Statistická verifikace	30
3.5.2	Ekonometrická verifikace	33
3.5.3	Ekonomická verifikace	40
3.6	Využití odhadnutého modelu	40
4	Zhodnocení vlivu vybraných faktorů na akciové environmentální indexy	41
4.1	Charakteristika vybraných proměnných	41
4.2	Formulace modelu.....	46

4.2.1	Ekonomická formulace modelu	46
4.2.2	Matematická formulace modelu	48
4.2.3	Ekonometrická formulace modelu.....	48
4.3	Analýza dat.....	49
4.3.1	Popisná statistika.....	49
4.3.2	Analýza chybějících, odlehlých a extrémních hodnot	50
4.3.3	Korelační analýza	51
4.4	Odhad jednofaktorových regresních modelů	53
4.5	Verifikace modelu.....	55
4.5.1	Statistická verifikace	55
4.5.2	Ekonometrická verifikace	58
4.6	Shrnutí jednofaktorových modelů.....	62
4.7	Vícefaktorové modely	63
4.7.1	Korelační analýza	64
4.7.2	Odhad vícefaktorových regresních modelů	64
4.7.3	Statistická verifikace	65
4.7.4	Ekonometrická verifikace	66
4.8	Vícefaktorové modely s transformovanými proměnnými	69
4.8.1	Korelační analýza	70
4.8.2	Odhad vícefaktorových regresních modelů	71
4.8.3	Statistická verifikace	71
4.8.4	Ekonometrická verifikace	72
4.9	Závěrečný vícefaktorový model.....	75
4.10	Shrnutí vícefaktorových modelů	76
4.11	Shrnutí výsledků regresní analýzy.....	78
5	Závěr	81

Seznam použité literatury	83
Seznam zkratek	87

1 Úvod

Téma ekologie je v dnešní společnosti jedno z nejdiskutovanějších. Slova jako životní prostředí, obnovitelné zdroje energie, klimatické změny, recyklace, šetrnost a mnoho dalších lze vidět denně v novinových a internetových článcích, slyšet v televizi a videích či z úst obyčejných lidí nebo vysoce postavených světových politiků. Ekologie a životní prostředí je jedno ze stálých témat, která hýbou světovou politikou. Na tom, jak se lidé postaví k problémům v oblasti životního prostředí, závisí budoucnost celé planety.

Někdo může dnešní svět vidět jako posedlý životním prostředím, ekologií a eko-výrobky. Mnoho obchodníků využívá, nebo zneužívá, těchto hesel k propagaci svých produktů. Lze říci, že v dnešní době předpona eko- nebo bio- prodává velice dobře. Zda jde o ušlechtilý záměr chránit planetu nebo jen zneužívání aktuální situace, musí již každý posoudit sám. Tento trend se nevyhnul ani finančním trhům. Existuje nespočet fondů, které proklamují, že ve svých portfoliích mají jen ekologicky smýšlející firmy, firmy vyrábějící energii z obnovitelných zdrojů, využívající pouze recyklovatelné materiály a podobně. Takzvané 'green bonds', doslovně přeloženo jako 'zelené dluhopisy', jsou dnes nabízeny na mnoha světových burzách. Emitenti takových dluhopisů se obvykle zavazují k použití získaného kapitálu na projekty podporující životní prostředí. V podobném duchu lze pokračovat dále.

Cílem této diplomové práce bude zjistit, zda nástroje finančních trhů s vazbou na životní prostředí jsou ve skutečnosti ovlivňovány změnami životního prostředí. Jinak řečeno, zda společnosti pouze nezneužívají pojmů, ale jejich vývoj je závislý na vývoji životního prostředí. Změny životního prostředí budou v práci zastoupeny čtyřmi faktory z této oblasti. Prvním faktorem je podíl energie z obnovitelných zdrojů na celkové vyrobené elektrické energii ve státech OECD. Druhý faktor je počet prodaných elektromobilů ve Spojených státech. Třetím a čtvrtým faktorem jsou úrovně hladiny metanu (CH_4) a oxidu uhličitého (CO_2) v atmosféře. Tyto plyny patří do skupiny tzv. skleníkových plynů. Finanční instrumenty budou shrnuty ve vývoji tří akciových indexů spadajících do skupiny S&P Global, konkrétně S&P Global Clean Energy Index, S&P Global Water Index a S&P Global Eco Index. Cílem této práce bude tedy zjistit, zda zvolené akciové indexy jsou ovlivněny vybranými faktory, konkrétně hodnotou podílu

energie z obnovitelných zdrojů v zemích OECD, objemem prodeje elektromobilů v USA a globálními změnami koncentrace CH_4 a CO_2 .

Předpokládaný vztah mezi faktory koncentrace CO_2 a CH_4 je takový, že v případě zvyšování hodnot koncentrace, bude hodnota firem zabývajících se vývojem a výrobou technologií na snižování koncentrace růst a tedy i hodnota indexu bude růst. Společnosti v bázích indexů jsou vybírány na základě přísných kritérií týkajících se mimo jiné hospodaření s emisemi CO_2 a CH_4 . Tyto firmy tak více než jiné dbají na jejich snižování. V případě faktoru objemu prodeje elektromobilů zvyšující se objem prodeje značí vyšší zájem veřejnosti o nové technologie a obnovitelné zdroje energie. Ten, kdo si pořídí elektromobil, jistě uvažuje i o tom odkud pochází elektrická energie pohánějící tento automobil. S růstem objemů prodeje lze tedy předpokládat růst hodnoty indexu a to především růst Clean Energy Indexu. Lze předpokládat také silnější vliv mezi tímto indexem a faktorem vývoje podílu energie z obnovitelných zdrojů. Opět očekávaný vztah je kladný.

Vztah mezi jednotlivými faktory a zvolenými indexy bude modelován pomocí metody lineární regresní analýzy. V rámci této analýzy budou vytvořeny odhady regresních modelů pomocí metody nejmenších čtverců. Modelování a následné testování bude provedeno v prostředí aplikace IBM SPSS Statistics, případně aplikace Microsoft Excel.

2 Charakteristika environmentálních aktiv

Environmentální aktiva tvoří samostatnou třídu aktiv, která byla vytvořena relativně nedávno. Akciové třídy jsou definovány jako skupiny finančních aktiv s podobnými vlastnostmi. Instrumenty stejné třídy obvykle vykazují velmi podobné chování na finančních trzích. Z historického hlediska existují tři základní třídy: akcie, dluhopisy a peněžní ekvivalenty, případně instrumenty peněžního trhu. Časem byla tato trojice rozšířena o řadu dalších tříd, například komodity, nemovitosti, forwardy a futury, opce a v poslední době také kryptoměny. Jednotlivé třídy se od sebe odlišují frekvencí příjmů, mírou rizika, možnosti obchodování a dalšími znaky. Rozdělení aktiv do tříd se využívá především při sestavování portfolií a zajišťování jejich diverzifikace. Dobře sestavené portfolio by mělo reflektovat povahu investora a obsahovat aktiva z více tříd. Pro investora je klíčové, že aktiva různých tříd se chovají v různých částech hospodářského cyklu jinak. Hodnota akcií stoupá v období hospodářského růstu, kdy naopak dluhopisy mají obvykle nízkou výnosnost.

Environmentální aktiva jako celek jsou shrnuty v publikaci *Environmental markets: A new asset Class* vydaná CFA Institute Research Foundation vydané v roce 2014. Tato publikace je jedna z prvních, která shrnuje a snaží se definovat environmentální aktiva. V publikaci jsou environmentální aktiva uspořádána do několika tříd: Znečištění kyselými dešti, Skleníkový efekt, Trh s čistou energií, Trh s vodou, Změny počasí a Udržitelnost.

V současné době se investoři nejčastěji setkávají s tzv. *Environmental Markets*, *Green Capital Markets*, *Green Bonds*, *Climate Bonds* a mnoho dalšími. Každá světová burza má dnes svou vlastní *Environmental policy*, své *Green Markets* a ve svých portfoliích aktiva a indexy spjaté s životním prostředím. Lze se domnívat, že v budoucnu tento sektor trhu s cennými papíry, i vzhledem k vývoji postoje společnosti ke klimatu a životnímu prostředí, bude nabývat na významu.

2.1 Akciové indexy


V následující podkapitole budou nejprve popsány akciové indexy z obecného hlediska. Následně budou charakterizovány tři vybrané akciové indexy společnosti S&P

Dow Jones Indices LLC. Tyto indexy pak budou figurovat jak závislé, neboli vysvětlované proměnné v modelech ekonometrického modelování.

Akciové indexy lze považovat za ukazatele výkonnosti určitého segmentu trhu nebo jinak specifikované oblasti. Indexy samy o sobě nejsou aktivem, ale pouze statistickým, souhrnným ukazatelem. I přesto lze s indexy obchodovat. Indexy ve své bázi zahrnují obvykle několik desítek akcií, jejichž podíl je dán jejich cenou nebo tržní kapitalizací. Báze indexu obsahuje veškeré akcie, které mají vliv na hodnotu indexu. Indexy jsou velmi oblíbené pro hodnocení výkonnosti investic. Jde o velmi transparentní nástroj, kde obvykle jde přesně zjistit, jak je index konstruován a jak je vyčíslována jeho hodnota. Shrnuje ve své podstatě výkonnost určité části akciového trhu, se kterou jde dobře porovnávat výnosnost jednotlivých akcií z tohoto segmentu.

Nejstarším indexem je Dow Jones Transportation Average (DJTA), který je vyčíslován od roku 1884. Nejznámějším a zároveň druhým nejstarším je Dow Jones Industrial Average (DJIA). Poprvé byl vypočten 26. května 1896. Jedná se o nejznámější a možná také nejsledovanější index na světě. Jde o cenově vážený index, který zahrnuje 30 nejvýznamnějších amerických akciových společností. Při jeho založení se jednalo výhradně o průmyslové podniky. Dnes slovo 'Industrial' v názvu je zavádějící, jelikož ne všechny společnosti jsou typicky průmyslové. Vždy jde ale o tzv. 'blue-chip' společnosti, tedy nejziskovější a nejvíce obchodované společnosti na burze, se stabilním růstem a pravidelným vyplácením dividend. Z toho vyplývá, že složení portfolia tohoto indexu není stabilní a časem se mění. Na počátku index dokonce obsahoval pouze 12 společností. V současné době, dle informací na stránkách S&P Dow Jones Indices, portfolio indexu zahrnuje například společnosti jako The Walt Disney Company, Walmart, Procter & Gamble, Nike, Microsoft, McDonald's, JPMorgan Chase, The Coca-Cola Company, Apple Inc. a další.

Obrázek 2.1 Vývoj indexu Dow Jones Industrial Average od jeho založení



Zdroj: <https://education.howthemarketworks.com/>

Akciové indexy jsou neodmyslitelně spjaty s burzami. Každá světová burza má svůj hlavní index, který je složen z nejlepších titulů obchodovaných na dané burze a pak řadu dalších indexů, zaměřených například na určitý sektor ekonomiky. Oficiálním indexem Pražské burzy cenných papírů je index PX. Jde o cenově vážený index složený z dvanácti nejlikvidnějších akcií. Aktuálně to jsou například akcie společnosti Avast, O2 C. R., Kofola ČS, Moneta Money Bank nebo ČEZ. Index byl poprvé vypočten v únoru 2015.

Další indexy nejznámějších světových burz jsou například FTSE 100, který zahrnuje sto společností s největší tržní kapitalizací na Londýnské burze. Veškeré společnosti obchodované na burze v New Yorku jsou zahrnuty v indexu NYSE Composite, který tak obsahuje 1 900 akcií. Tokijská burza sloučila akcie obchodované v tzv. První sekci do indexu TOPIX. Burza v Hongkongu mimo jiné spravuje index HSI Hang Seng, který zahrnuje 35 titulů kótovaných na této burze.

2.1.1 S&P Dow Jones Indices LLC

Společnost S&P Dow Jones Indices LLC vznikla v roce 2012 spojením společností S&P Indices a Dow Jones Indexes. Zrodil se tak největší poskytovatel indexů finančních trhů na světě. Společnost je důležitým zdrojem dat pro mnoho statistických výzkumů a analýz nejen finančního trhu. Vlajkovými loděmi jsou bezesporu indexy S&P 500 a Dow Jones Industrial Average. Denně jsou investovány ohromné částky na základě indexů této společnosti. Jeden ze základních kamenů, na kterých společnost staví svůj úspěch, jsou neustálé inovace a rozvoj indexů napříč celým spektrem jednotlivých tříd aktiv. Společnost S&P Dow Jones Indices LLC je z větší poloviny vlastněna S&P Global, menšinovým vlastníkem je pak společnost CME Group Inc., která je držitelem licence na indexy skupiny S&P DJI a zastřešuje získávání dat.

2.1.2 S&P Global Water Index

Index S&P Global Water obsahuje ve svém portfoliu obchodovatelné společnosti z celého světa podnikající ve vodohospodářském průmyslu. Tyto společnosti byly vybrány na základě požadované diverzifikace portfolia, lze je však rozdělit do dvou stejně početných skupin. V první jsou společnosti zabývající se vodohospodářským zařízením a infrastrukturou pro distribuci vody. V druhé skupině jsou společnosti zabývající se vodohospodářským vybavením a materiálem, především pro úpravu vody. Společnosti v bázi indexu musí rovněž splňovat určitá ekologická kritéria, takzvané uhlíkové charakteristiky. Jedná se o dva podílové ukazatele, emise CO₂ k hodnotě investic a emise CO₂ k celkovým příjmům. Dalšími kritérii jsou vážený průměr intenzity vypouštěného CO₂ a emise z fosilních paliv, u kterých je nastavena nulová tolerance. Hodnoty CO₂ u prvních třech kritérií jsou měřeny na prvním stupni výroby, při prvotním zpracování surovin a v rámci prvního článku dodavatelského řetězce. Vývoj indexu během posledních deseti let je znázorněn v obrázku 2.2.

Obrázek 2.2 Vývoj S&P Global Water Indexu v posledních 10 letech



Zdroj: <https://us.spindices.com/indices/equity/sp-global-water-index>

Celkem je index složen z padesáti společností. Mezi nejvýznamnější patří např. American Water Works Co Inc, Veolia Environment nebo Aqua America Inc. Více než polovina, přesněji 26, společností je amerických, 4 společnosti jsou z Velké Británie a 3 z Japonska. Hodnota indexu je stanovována od února roku 2007. Váhy jednotlivých společností v indexu jsou stanoveny na základě tržní kapitalizace. Tržní kritéria, která musí všechny tyto firmy splňovat, jsou následující:

- celková tržní kapitalizace minimálně 250 milionů USD,
- Tržní kapitalizace v minimální výši 100 milionů USD,
- průměrný objem obchodů za tři měsíce minimálně v hodnotě 1 milionu USD (pro společnosti z aktuálního portfolia stačí 500 000 USD),
- akcie obchodované na jedné z předních burz.

2.1.3 S&P Global Clean Energy Index

Portfolio toho indexu je složeno z obchodovatelných společností zabývajících se čistou energií, tedy energií z obnovitelných zdrojů. Jedná se o podniky přímo vyrábějící čistou energii nebo podniky, které dodávají potřebné vybavení a materiál pro produkci energie z obnovitelných zdrojů. V rámci pravidel pro posuzování vhodnosti společností pro tento index je za zelenou energii považována energie vyrobená v solárních, větrných a geotermálních elektrárnách, hydroelektrárnách a elektrárnách na biomasu. Index existuje od února 2007. V obrázku 2.3 je znázorněn vývoj indexu za posledních deset let.

Obrázek 2.3 Vývoj S&P Global Clean Energy Indexu v posledních 10 letech



Zdroj: <https://us.spindices.com/indices/equity/sp-global-clean-energy-index>

Celkem je v portfoliu třicet společností, které opět musí splňovat již výše popsané uhlíkové charakteristiky. Požadované hodnoty ukazatelů se však liší, nejsou tak přísné jako u Global Water Indexu. Tržní charakteristiky jsou taktéž obdobné:

- celková tržní kapitalizace musí činit minimálně 300 milionů USD,
- Tržní kapitalizace v minimální výši 100 milionů dolarů,
- průměrný objem obchodů za tři měsíce minimálně v hodnotě 3 milionu USD (pro společnosti z aktuálního portfolia stačí 2 miliony USD),
- akcie obchodované na jedné z předních burz.

2.1.4 S&P Global Eco Index

S&P Global Eco Index není tak úzce zaměřený jako dva předcházející indexy. Portfolio je složeno ze společností, které vyvíjejí své aktivity ve třech různých odvětvích neboli klastrech spojených s ekologií. Tyto klastry jsou definovány jako čistá energie, služby v oblasti životního prostředí a voda. V prvním klastru je 15 společností, v druhém 10 a posledním opět 15. Celkem se tedy portfolio indexu skládá ze 40 společností. Zároveň všechny tyto společnosti jsou již obsaženy v portfoliích indexů odpovídajících jednotlivým klastrům. Konkrétně to jsou indexy S&P Global Clean Energy Index, od kterého je přesně odvozen název skupiny, stejně jako od S&P Global Water Index. Druhá skupina je vybrána z báze indexu S&P Global BMI Environmental & Facilities Services. Hodnota indexu je stanovována od ledna 2008. Vývoj indexu za posledních deset let znázorňuje obrázek 2.4.

Obrázek 2.4 Vývoj S&P Global Eco Indexu v posledních 10 letech.



Zdroj: <https://us.spindices.com/indices/equity/sp-global-clean-energy-index>

Všechny podniky musí opět splňovat takzvaná uhlíková kritéria, jejichž hodnoty jsou velmi podobné jako u Global Clean Energy Indexu. Tržní kritéria tohoto indexu jsou také obdobná jako u dvou předcházejících:

- celková tržní kapitalizace musí činit minimálně 500 milionů USD,
- Tržní kapitalizace v minimální výši 200 milionů USD,
- průměrný objem obchodů za tři měsíce v minimální výši 2 milionu USD (pro společnosti z aktuálního portfolia stačí 1 milion USD),
- akcie obchodované na jedné z předních burz.

2.2 Vybrané faktory charakterizující životní prostředí

Následující podkapitola bude věnována vybraným faktorům charakterizujících vývoj životního prostředí. Faktory byly zvoleny tak, aby korespondovaly se zvolenými akciovými indexy, aby splňovaly nárok na množství a frekvenci dat a v neposlední řadě aby z různých úhlů popisovaly životní prostředí.


2.2.1 Koncentrace oxidu uhličitého v atmosféře

Oxid uhličitý, latinsky dioxidum carbonis, sumární vzorec CO_2 , je bezbarvý plyn bez chuti a zápachu. Molekula je tvořena dvěma atomy kyslíku a jedním atomem uhlíku. Oxid uhličitý vzniká při dýchání, při spalování fosilních paliv, biomasy a bioplynu nebo během kompostování. Tento plyn je nedýchatelný, ve vyšší koncentraci

může způsobit ztrátu vědomí a později i smrt. Je běžnou součástí atmosféry, přičemž v závislosti na lokálních podmínkách je někde jeho koncentrace vyšší, než je obvyklé, například v blízkosti aktivních vulkánů nebo pramenišť přírodních minerálních vod. V pevném skupenství se nazývá suchý led, sublimuje přibližně při -80°C . V současnosti je oxid uhličitý nejvíce spojován s problémem globálního oteplování a jeho zvyšující se koncentrace je považována za jednu z jeho hlavních příčin. Nejvíce je sledována koncentrace v atmosféře, přitom dle výzkumů Yalské univerzity koncentrace v půdě je dvakrát vyšší a v oceánu dokonce padesátkrát vyšší než v atmosféře. Oxid uhličitý je na výrobu nenáročný plyn, a proto má široké využití v mnoha odvětvích průmyslu, například při výrobě polykarbonátu, jako ochranná atmosféra nebo sytidlo perlivých nápojů v potravinářství, náplň sněhových hasicích přístrojů, chladicí medium nebo hnojivo. V přírodě je neznámější jeho využití při fotosyntéze, kdy rostliny jej přeměňují na kyslík a glukózu.

Mezi laickou veřejností převládá názor, že oxid uhličitý je jeden z hlavních viníků globálního oteplování. Faktem je, že koncentrace oxidu uhličitého v atmosféře je mnohonásobně vyšší, než jaká byla před stovkami let. Tento vývoj je znázorněn v obrázku 2.5. Na svislé ose je hodnota koncentrace oxidu uhličitého v atmosféře v jednotkách ppm. Na vodorovné ose je odpočítáván počet let od současnosti, tedy počátek grafu zachycuje koncentraci v období před 800 lety. Historické hodnoty jsou získávány pomocí výzkumu ledovcových vrtů, mimo jiných také organizací NASA.

Obrázek 2.5 Vývoj koncentrace oxidu uhličitého v atmosféře v jednotkách ppm



Zdroj: <https://climate.nasa.gov/vital-signs/carbon-dioxide/>

Ovšem tento problém je mnohem složitější a komplexnější. Existují také studie, které naopak tvrdí, že vyšší hladina CO_2 je až příčinou postupného oteplování. Velké množství tohoto plynu je rozpuštěno v mořích a oceánech. Zvyšující se teplota vody však jeho schopnost rozpouštět se negativně ovlivňuje a má za následek jeho opětovné uvolňování do ovzduší. Je nezpochybnitelné, že nárůst koncentrace CO_2 je důsledkem lidské činnosti, především průmyslové výroby. Na tuto příčinu se zaměřuje mnoho politiků, kteří bojují za snižování emisí CO_2 , a tím zpomalení globálního oteplování, mají jako jeden z hlavních bodů svých volebních programů. V důsledku změn klimatu vzniklo mnoho dalších přírodních zdrojů CO_2 . V ekosystému jde přesněji o postupnou ztrátu schopnosti některých jeho prvků CO_2 pohlcovat. Příkladem mohou být rozsáhlejší lesní požáry, z důvodu vyššího sucha, které ničí více vegetace schopné CO_2 pohlcovat. Sucho také může bránit rychlejší obnově vegetace. Velký objem oxidu uhličitého z ovzduší zpracovává mořský fytoplankton. Pro tento proces je ale velmi důležité optimální prostředí, především co se týče teploty vody. V důsledku ohřívání oceánů tak dochází ke ztrátě tohoto ideálního prostředí a snižování schopnosti fytoplanktonu zpracovávat CO_2 . Faktorů, které mohou za zvyšování hladiny oxidu uhličitého v ovzduší, je tedy mnoho a dodnes neexistuje jednoznačná teorie definující jeho příčinu a vliv na životní prostředí.

NASA

NASA je nezávislá americká vládní agentura. Celý název zní Národní úřad pro letectví a kosmonautiku. Vznikla v roce 1958 a soustřeďovala veškeré nevojenské aktivity v oblasti výzkumu vesmíru. Sídlo organizace se nachází ve Washingtonu, největší kosmodrom je v Kennedyho vesmírném středisku na Floridě, další zařízení a vědecká centra jsou rozesety po celých Spojených státech. Ve svých počátcích se organizace soustředila především na možnost letu člověka do vesmíru. Za své existence vytvořila a realizovala desítky vesmírných programů. V současnosti NASA zastřešuje mnoho institutů a výzkumů, které již s vesmírem nebo letectvím nemají přímou souvislost. Jedním z nich je projekt Global Climate Change: Vital Signs of the Planet, která vznikla v návaznosti na angažování se organizace NASA do výzkumu klimatu. NASA se dnes prezentuje jako jedna z předních světových agentur pro výzkum klimatu. Cílem tohoto projektu je poskytovat veřejnosti přesné a aktuální informace o klimatu a jeho změnách a dopadech na naši planetu. Pomocí technologií NASA jsou shromažďována data, která jsou následně zpracovávána do databází. Součástí projektu

jsou také rozsáhlé odborné články, které reflektují nové výzkumy a poznatky v oblasti klimatu. Projekt se zaměřuje na sběr dat v pěti oblastech: oxid uhličitý, globální teplota, arktické ledovce, permafrost a hladina oceánů. Data koncentrace CO₂ ve vzduchu jsou získávány na observatoři Mauna Loa na Havaji. Historická data jsou pak zjišťována pomocí analýzy ledovcových vrtů na Antarktidě. Hladina koncentrace je udávána v jednotkách ppm, parts per million, tedy počet molekul CO₂ v jednom miliónu molekul vzduchu. Veškeré hodnoty koncentrace jsou dostupné pro veřejnost na stránkách projektu Global Climate Change.


2.2.2 Koncentrace metanu v atmosféře

Methan, v češtině také někdy psáno jako metan, je nejjednodušší uhlovodík, sumárním vzorcem zapsán CH₄. V pokojové teplotě má plynné skupenství, je bez barvy a zápachu, vysoce hořlavý a výbušný již v malých koncentracích. Laicky je někdy označován jako bahenní plyn. Přirozeně se vyskytuje v atmosféře, kde se dostává uvolňováním z rozkladu látek bioplynu, jako produkt metabolismu přežvýkavců a termitů nebo anaerobním rozkladem organické hmoty (hnitím). Právě z přirozených organických procesů vzniká většina metanu na Zemi. Tvoří hlavní složku zemního plynu, je součástí důlního plynu a také ropy. Dále se uvolňuje při požárech, sopečných erupcích nebo z mořské hladiny. V rámci činnosti člověka je největší množství tohoto plynu uvolňováno v zemědělské produkci, průmyslu se zemním plynem a jeho skladováním a těžbě uhlí. Velké zásoby metanu se nacházejí v podzemních zásobnících nebo trvale zmrzlé půdě, takzvaném permafrostu. Metan se využívá v podobě CNG-stlačeného zemního plynu jako palivo v průmyslu, domácnostech a v osobní a nákladní dopravě.

Stejně jako oxid uhličitý i metan patří mezi takzvané skleníkové plyny. Silně absorbuje infračervené záření a tím způsobuje zvyšování teploty v atmosféře. Dle výzkumů je jeho vliv na teplotu vyšší než vliv CO₂, jeho obsah v atmosféře je však mnohonásobně menší, tudíž celkový vliv je také nižší. Koncentrace metanu v atmosféře v posledních letech radikálně roste, což lze dobře pozorovat v obrázku 2.6. Obrázek znázorňuje vývoj hodnoty koncentrace metanu za více než 1000 let. Za největší producenty je považován chov dobytka, průmysl a skládky. V poslední době nejvíce diskutována oblast vzniku metanu je právě chov hospodářských zvířat, přesně velkých

přezvýkavců, například skotu. Některé nejnovější studie ukazují, že právě chov skotu se největší měrou podílí na zvyšující se hladině metanu v atmosféře, jak uvádí například zpráva organizace LEAD.

Obrázek 2.6 Vývoj koncentrace metanu v atmosféře v jednotkách ppb



Zdroj: <https://www.methanelevels.org/>

Institut 2° Celsia

Institut 2° Celsia je neziskovou pobočkou organizace Clean Air Society of Sunshine Coast se sídlem v kanadském městě Sechelt na západním pobřeží Britské Kolumbie. Od roku 2003 se tento institut zaměřuje na edukaci a šíření povědomí o dopadech používání černého uhlí a dalších formách znečišťování a jejich vliv na zdraví lidí a životní prostředí. Snaží se podporovat rozvoj strategií, které se snaží u lidí podnítit změny v chování a životním stylu potřebné k udržení globálního oteplování pod úrovní 2°C, což je hodnota předindustriální doby. S institutem spolupracují renomovaní klimatologové i vědci jiných oborů ze světových univerzit. Na rozdíl od jiných podobných organizací, se 2°Celsia snaží cílit své úsilí přímo na lidi, ne na vlády nebo mezinárodní organizace. Jedním z cílů je, aby si lidé uvědomili, že i oni mají svůj podíl na globálním oteplování. Průměrná uhlíková stopa obyvatele Severní Ameriky je zhruba čtyřnásobná oproti celosvětovému průměru. Je zde tedy jasný cíl a příležitost podnítit určité změny. Uhlíková stopa průměrného jedince se skládá z emisí skleníkových plynů z následujících odvětví: cestování, energie v domácnostech, potraviny, zboží a služby. Na základě těchto myšlenek se institut snaží nabídnout jasný a dosažitelný plán pro jednotlivce, jak významně snížit svou uhlíkovou stopu. Institut vytváří interaktivní klimatické grafy, které jsou k dispozici jak vědcům nebo pedagogům tak laické

veřejnosti pro lepší pochopení role zvyšující se hladiny skleníkových plynů v procesu změny klimatu.

Prezentované hodnoty hladiny CH_4 vycházejí od roku 1983 z měření institutu The Global Monitoring Division of NOAA's Earth System Research Laboratory, která využívá síť měřících bodů po celém světě. Data do roku 1983 jsou odvozována z výzkumu ledovcových vrtů na Antarktidě. Data prezentována na stránkách institutu jsou aktualizována každý měsíc, přičemž hodnoty jsou zveřejňovány se zpožděním tří měsíců, aby byla zajištěna co největší přesnost. Hodnoty jsou uváděny v jednotkách ppb, parts per billion, tedy počet molekul CH_4 na jednu miliardu molekul vzduchu.

2.2.3 Objem prodeje elektromobilů a plug-in hybridů

Předpokládat, že elektromobilita je fenomén několika posledních let, by byla velká chyba. První myšlenka vozidla na elektrický pohon přišla již v první polovině 19. století jako možná alternativa k parnímu pohonu. Ve vývoji prvních elektromobilů lze nalézt i českou stopu. František Křižík v roce 1885 představil vlastní elektromobil s 42 olověnými články a motorem o výkonu 3,6 kW. Po období prototypů v 19. století, na počátku 20. století měly elektromobily na trhu již 40 %. Velkým problémem byl ovšem nízký dojezd a provozní rychlost. Po objevení spalovacího motoru a obrovském boomu automobilů na benzínový pohon, byla elektromobilita a její vývoj na nějakou dobu upozaděn. Dalšími faktory, které zpomalily vývoj elektromobilů, bylo především uvedení Fordu model T v roce 1908 a velmi nízká cena benzínu. Spalovací motory prošly mohutným vývojem a jejich pozice byla dlouho neotřesitelná. Zlom přišel v roce 1973, kdy probíhala tzv. jomkipurská válka, v rámci níž arabská ropná organizace OAPEC vyhlásila embargo na dodávky ropy do mnoha zemí včetně USA, Japonska nebo Spojeného království. Tato událost je více známá jako 'první ropný šok'. Cena ropy v té době vzrostla čtyřikrát, z 3 na 12 dolarů za barel. V období druhého ropného šoku o šest let později se cena vyšplhala až na 40 dolarů za barel. Ropa přestala být levnou a jistou komoditou, což byl jeden z důvodů začít hledat alternativní pohon. Vývoj elektromobilů začal zažívat renesanci. Bohužel ne z důvodu emisí a znečišťování životního prostředí výfukovými zplodinami. Tato motivace přišla až později, zejména v posledních dvou dekádách 20. století. Největší a nejvýznamnější pokroky se odehrávaly ve Spojených státech, především v Kalifornii. Na přelomu tisíciletí měla již skoro každá

známá značka ve svém portfoliu automobil čistě na elektrický pohon, za zmínku stojí například Honda EV Plus, Toyota RAV4 EV nebo Nissan Altra EV. Dalším klíčovým bodem ve vývoji elektromobility bylo v roce 2008 představení modelu Tesla Roadster, který představoval naprostý průlom a nechal všechny dosavadní elektromobily daleko za sebou. Tesla tak položila základy moderní elektromobily.

V dnešní době je snaha na národní a nadnárodní úrovni prosazovat elektromobilitu jako jedinou cestu v budoucím automobilovém průmyslu. V mnoha zemích existují určité kvóty, limity a nařízení ohledně rozvoje elektromobilů, a naopak omezování spalovacích motorů, které jsou automobilky nuceny dodržovat. Automobilky se snaží elektromobily prezentovat jako běžná rodinná auta, ne jako něco futuristického jen pro horní vrstvu společnosti. Stále je však rozdíl v ceně benzínového auta a elektromobilu značný. Zvyšující se poptávka, však přináší naději na budoucí snížení ceny a masové rozšíření elektromobilů.

Technologie plug-in hybrid je označení pro automobily, které lze dobít z externího zdroje elektrické energie, tedy zásuvky. Tyto automobily lze provozovat zcela bez použití spalovacího motoru, tedy bez produkce emisí. Spalovací motor však auto obsahuje a je nutný jeho pohon při delších cestách. V této práci byly použity statistiky jak prodeje plug-in hybridních automobilů (PHEV) tak automobilů na čistě elektrický pohon (EV) ve Spojených státech od roku 2011. Ač právě v USA nejsou žádná omezení na spalovací motory, trh s elektromobily je jeden z nejrozvinutějších. Nejvýraznějším hráčem na americkém trhu s elektromobily je bezesporu Tesla. Její Tesla Model S je nejprodávanějším elektromobilem na světě vůbec. Je v prodeji od roku 2012 a jen ve Spojených státech se prodalo přes 150 000 kusů. Nejprodávanějším modelem se stala ale až v roce 2015. Do té doby byly před ní například Chevrolet Volt, Nissan LEAF nebo Toyota Prius PHV. Chevrolet Volt byl v roce 2011 vůbec nejprodávanější plug-in hybrid vůbec a na předních příčkách se drží dodnes. V průběhu let stoupal, jak celkový počet prodaných vozů, tak počet značek, jež měly ve svém portfoliu automobil s elektrickým pohonem. Dnes je běžné, že automobilky mají v nabídce více než jeden plug-in hybrid nebo automobil čistě na elektrický pohon. Aktuální informace, statistiky a analýzy z oblasti elektromobility shromažďuje na svých stránkách společnost InsideEvs.

InsideEVs

InsideEVs je americká společnost sídlící v Miami. Vznikla se záměrem přinášet skrze webové stránky nejaktuálnější novinky ze světa plug-in hybridů a elektromobilů. Přibližovat tak tento svět laické veřejnosti a vysvětlovat, jak tyto automobily fungují a proč právě o elektromobily by se měli lidé čím dál více zajímat. Dnes má tato společnost mnohaleté zkušenosti v oblasti elektromobility a je největší internetovou doménou, která se komplexně zabývá novinkami v této oblasti automobilového průmyslu. Společnost vlastní celou skupinu webových stránek EV Network, kde InsideEVs je jejich vlajkovou lodí. Společnost sdružuje desítky významných a renomovaných profesionálů z tohoto odvětví, kteří přispívají svými články a studiemi. V současné době, kromě domovského Miami, má společnost pobočky také v Paříži, Římě a brazilském Sao Paulu.

2.2.4 Podíl energie z obnovitelných zdrojů v zemích OECD

OECD je organizace založena za účelem ekonomické spolupráce a rozvoje, jak členských, tak nečlenských států. Jedná se o mezinárodní vládní organizace sídlící v Paříži. Vznik se datuje do roku 1961, kdy vešel v platnost zakládající dokument organizace „Konvence o OECD“. V tomto dokumentu jsou definovány hlavní cíle organizace jako spolupráce a koordinace politických kroků za účelem dlouhodobého ekonomického rozvoje členských i nečlenských zemí. Organizace tak hraje důležitou roli v oblasti mezinárodních ekonomických vztahů. Členské státy patří mezi ekonomicky nejvýznamnější státy světa, dohromady produkují více než dvě třetiny světové produkce zboží a služeb (dle MZV). Fungování OECD je založeno na nepřetržitých dialogích mezi jednotlivými členskými státy. Předmětem dialogů jsou postupy a jejich uplatnění v dalších zemích v mnoha oblastech národního hospodářství, např. ekonomii, financích, obchodu, vzdělávání, životním prostředí, zemědělství a mnoha dalších.

Organizaci zakládalo 18 evropských států, např. Velká Británie, Švýcarsko, Itálie, Francie nebo Norsko, společně s Kanadou a USA. Postupem času se k organizaci připojilo dalších 16 států ze všech kontinentů. Česká republika je členským státem od roku 1995. Organizace je tak schopna podněcovat diskuze a změny na globální úrovni. Krom členských států, organizace úžeji spolupracuje s další pěticí nečlenských států,

kteře jsou také jedni z největších hráčů světové ekonomiky, např. Čínou, Brazílií nebo Indií. OECD dále spolupracuje s řadou dalších mezinárodních organizací např. WTO. Politika a myšlenky OECD jsou formulovány jako nezávazná doporučení a je jen na členských státech zda, je uplatní. Analýzy, statistiky a další dokumenty vzniklé pod hlavičkou OECD jsou brány jako velmi objektivní, nepolitické a odborné. Jsou dále používány ve státních statistikách, analýzách soukromých společností nebo například pro potřeby univerzit.

Obnovitelné zdroje energie jsou specifické nemožností vyčerpatelnosti a vlivem na životní prostředí. Obnovitelné, neboli alternativní zdroje, jsou teoreticky nevyčerpatelné, což je největší rozdíl oproti klasickým, neobnovitelným zdrojům, jako je například ropa, uhlí, zemní plyn, jádro nebo také rašelina. Mezi energií získanou z alternativních zdrojů se řadí sluneční, vodní, větrná, geotermální energie, energie z biomasy a energie prostředí, získávána skřze tepelné čerpadlo. V české legislativě jsou obnovitelné zdroje energie přesně definovány v Zákoně 165/2012 Sb. o podporovaných zdrojích energie. Ve svých normách tuto energetickou problematiku upravuje i Evropská Unie, která si dala za cíl, aby v roce 2020 energie z obnovitelných zdrojů tvořila 20 % spotřebované elektřiny v Evropské Unii. Jde tedy o průměr, tudíž každá členská země si stanoví svůj cíl. Česká republika se zavázala v roce 2020 vyrábět 13 % produkce elektrické energie z alternativních zdrojů. V této oblasti si ČR vede velmi dobře, zatímco v roce 2005 měly obnovitelné zdroje 4,4 % podíl na celkové produkci, v roce 2014 to bylo už přes 13 %. Určitý vývoj lze také sledovat ve využívání jednotlivých alternativních zdrojů. Na počátku tisíciletí byl nejvyužívanější obnovitelný zdroj voda. Dnes má výrazný podíl energie získávána z bioplynu, biomasy a z fotovoltaických systémů.

V analýzách OECD v oblasti energetiky jsou mezi obnovitelné zdroje zařazeny vodní, geotermální, solární, fotovoltaická, sluneční, termální a větrná energie, energie z přílivu, a v posledních letech také rozvíjející se zdroj energie mořské vlny. Organizace spravuje rozsáhlé databáze statistik v mnoha oblastech. Kromě grafů a tabulek jsou výstupem také pravidelné reporty a rozsáhlejší publikace. Databáze je rozdělená dle témat na 12 oblastí, zemědělství, rozvoj, ekonomie, vzdělání, energie, životní prostředí, finance, politika, zdravotnictví, inovace a technologie, trh práce a společnost. Členské státy organizace mají k dispozici kvalitní zdroj dat pro srovnávání s jinými členskými

státy nebo průměrem všech zemí. Analýzy jsou dostupné na stránkách organizace IEA nebo také na OECD.Stat.

3 Popis metody lineární regrese analýzy

V následující kapitole je nejprve obecně charakterizována podstata ekonometrie. Dále jsou popsány jednotlivé části metodiky ekonometrické analýzy, definován proces ekonometrické analýzy a jeho dílčí kroky. Informace pro tuto kapitolu jsou čerpány především z publikací Hančlová (2012), Hušek (2007), Cipra (2013) a Arlt a Rublíková (2002)

3.1 Ekonometrie

Ekonometrie je vědní disciplína spojující poznatky ze tří oborů: matematiky, ekonomie a statistiky. V posledních letech je k nim často přidáván ještě obor informatiky. V různých publikacích je ekonometrie definována různě, ovšem tyto čtyři vědní disciplíny se v definicích vyskytují vždy. Dle Huška (2007) je úkolem ekonometrie mimo jiné dát ekonomické teorii alespoň aproximativně empirický obsah. Hančlová (2012) ve své publikaci uvádí stručné vymezení ekonometrie jako vědní disciplíny, jejímž cílem je pomocí nástrojů kvantitativní a kvalitativní analýzy ověřovat závěry ekonomických teorií s využitím matematických nástrojů a statistické dedukce.

3.2 Formulace modelu

Formulace modelu ze tří základních hledisek je prvním krokem procesu ekonometrického modelování. Formulaci modelu dělíme na ekonomickou, matematickou a ekonometrickou

Formulace ekonomického modelu zahrnuje stanovení objektu zkoumání, charakteristiku ekonomických veličin, vymezení a popis vazeb a vztahů mezi zkoumanými veličinami a v neposlední řadě formulaci výchozí hypotézy. Hypotéza je základní předpoklad, tvrzení o předpokládaném chování vybraných veličin. Pomocí výsledného ekonomického modelu by mělo být možné ve zjednodušené podobě popsat podstatu ekonomického problému.

Matematická formulace modelu zahrnuje vymezení klíčových proměnným modelu, dále převedení ekonomického modelu do analytické podoby funkčního

předpisu. Zde se již jednotlivé matematické formulace mohou lišit dle toho, zda je použit jednorovnicový nebo víceroovnicový systém a zda vztahy v modelu jsou lineární či nelineární. V této práci bude použit jednorovnicový systém s lineárními vazbami. Posledním krokem před vytvořením jednoduchého lineárního modelu je stanovení očekávaných vztahů, pozitivních nebo negativních, případně i dalších omezení, důležitých pro další postup. Výstup je ve formě rovnice charakterizující vztah závislé (vysvětlované) proměnné a nezávislé, popř. více nezávislých proměnných, znázorněno v rovnici 3.1.

$$Y_t = \beta_1 + \beta_2 \cdot X_t, \quad (3.1)$$

kde Y_t je závislá proměnná, X_t je nezávislá proměnná, β_1 je úrovněová konstanta neboli absolutní člen a β_2 je regresní koeficient udávající sklon.

Poslední formulací je formulace ekonometrického modelu. Tento model zavádí do již dříve formulované matematické rovnice takzvanou náhodnou složku. Předchozí model bylo možné nazvat deterministickým, zavedením náhodné složky se model stává již stochastickým. Rovnici stochastického modelu lze zapsat následovně:

$$Y_t = \beta_1 + \beta_2 \cdot X_t + \varepsilon_t, \quad (3.2)$$

kde ε_t je náhodná složka.

3.3 Sběr a analýza dat

Sběr a analýza dat představují druhou etapu ekonometrického modelování. V této fázi je důležité získat a následně pracovat s relevantními daty. Často je nutné získaná data adekvátně upravit do takové podoby, aby bylo možné dosáhnout stanovených cílů modelování. Zdrojem vhodných dat jsou databáze vládních institucí, národních i nadnárodních organizací, domácích i zahraničních institutů a dalších. Vhodnou databází je nutné volit na základě oblasti, na kterou je ekonometrické modelování zaměřeno. Cipra (2013) ve své publikaci rozděluje data na časová ve formě časových řad, průřezová ve formě průřezového výběru a panelová, což je kombinace časových a průřezových. V této práci byly používány data ve formě časových řad. Soubor dat je nutné podrobit pečlivé analýze, po které zpravidla následují vhodné úpravy.

V rámci této fáze je provedena popisná statistika dat, v rámci níž jsou charakterizována například minima a maxima, dále rozptyl a střední hodnota. Dále je provedena grafická analýza odlehklých a extrémních hodnot pomocí box-plotů. Box-plot, jiným názvem krabicový diagram nebo krabička s vousy, znázorňuje medián a první a třetí kvartil (tělo box-plotu, krabička). Krabička tedy představuje mezikvartilové rozpětí. Vousy označují maximální a minimální hodnoty, neměly by být delší než 1,5násobek krabičky. Za odlehlé hodnoty jsou považovány ty, které přesahují 1,5násobek krabičky. Extrémní hodnoty přesahují trojnásobek mezikvartilového rozpětí a pro další postup je nutné je nahradit.

Při analýze lze také dojít k zjištění, že časová řada je neúplná, jsou tedy zjištěny chybějící hodnoty. Tyto hodnoty, stejně jako extrémní hodnoty, je nutné nahradit vhodnou metodou. Jedná se například o nahrazení průměrem časové řady, průměrem dvou sousedních hodnot nebo použitím lineární interpolace.

Do analýzy časových řad lze zahrnout také její dekompozici na čtyři složky, trendovou, cyklickou, sezónní a náhodnou. Trend představuje dlouhodobou vývojovou tendenci, nelze jej tedy určit z krátkodobých časových řad. Není bezpodmínečně nutné, aby časová řada měla stále rostoucí či klesající trend, za změnu trendu však nelze považovat krátkodobé výkyvy. Cyklická složka je navázána na střídání fází poklesu a růstu. Nejtypičtějším příkladem jsou fáze ekonomického cyklu v tržní ekonomice. Sezónní složka se vyznačuje periodickým kolísáním v průběhu určitého časového intervalu, např. jednoho roku, který se vždy opakuje. Typickým příkladem je sezónnost v rámci ročních období. Tyto tři složky jsou systematické neboli deterministické. Poslední složka, náhodná, je oproti tomu nesystematická, vyjadřující náhodné chyby. Dekompozice časových řad se provádí z důvodu nutnosti očištění časové řady o sezónní složku. Arlt a Rublíková (2002) ve své publikaci uvádějí dvě možné metody dekompozice, aditivní a multiplikativní. Aditivní metoda dekompozice předpokládá, že součet jednotlivých složek tvoří výslednou časovou řadu. Tento vztah je znázorněn rovnicí 3.3. Multiplikativní metoda vychází z předpokladu, že časová řada je součinem jednotlivých složek. Tuto metodu dekompozice znázorňuje rovnice 3.4.

$$y_t = T_t + S_t + C_t + \varepsilon_t, \quad (3.3)$$

$$y_t = T_t \cdot S_t \cdot C_t \cdot \varepsilon_t, \quad (3.4)$$

kde y_t je časová řada, T_t je trendová složka, S_t je sezónní složka, C_t je cyklická složka a ε_t je náhodná složka.

Poslední součástí analýzy časové řady může být její transformace. Transformací lze vyřešit problém stacionarity. Stacionární časová řada je definována jako časová řada, jejíž rozložení pravděpodobnosti se v čase nemění. Stacionární časová řada je taková, která nevykazuje trend, její střední hodnota a variabilita je v čase konstantní a kovariance ve dvou různých časových obdobích jsou závislá pouze na vzdálenosti v čase. Transformovat lze například pomocí použití diferencí, logaritmů nebo relativních přírůstků. Matematicky lze transformace vyjádřit rovnicemi 3.5, 3.6 a 3.7.

$$y_t^* = y_t - y_{t-1} \quad (3.5)$$

$$y_t^* = \ln(y)_t \quad (3.6)$$

$$y_t^* = \frac{y_t - y_{t-1}}{y_{t-1}} \quad (3.7)$$

3.4 Odhad parametrů modelu

Čtvrtá fáze ekonometrického modelování zahrnuje především výběr vhodné metody pro odhad ekonometrického modelu. Tento výběr je dle Hančlová (2012) závislý především na charakteru ekonometrického modelu, vlastnostech časových řad, složitosti modelovaného systému nebo dostupnosti technického a softwarového vybavení. V této práci bude použita metoda odhadu s omezenou informací, kde odhady jednotlivých rovnic jsou prováděny zvlášť, konkrétně zde metodou nejmenších čtverců. Druhá možná metoda je metoda s úplnou informací, kde je odhadován vícerovniceový systém najednou.

V této fázi modelování je provedena korelační a regresní analýza vhodnou metodou. Výstupem korelační analýzy je koeficient korelace, který udává sílu lineární závislosti mezi dvěma proměnnými. Tento koeficient může nabývat hodnot z intervalu $\langle -1, 1 \rangle$. Hodnota koeficientu blízká nule značí minimální vzájemnou korelaci. Pro ekonometrické modelování je žádoucí, aby mezi jednotlivými proměnnými byla vzájemná korelace co nejmenší. Pokud je zjištěna silná míra vzájemné závislosti je nutné jednu z proměnných z modelu vyloučit.

Regresní analýza je jedním z nejdůležitějších ekonometrických nástrojů. Slouží ke kvantitativnímu popisu vztahů mezi jednotlivými proměnnými. Jinak řečeno, pomocí regresní analýzy lze popsat změny hodnot určité proměnné změnami hodnot jiných proměnných. Určitá proměnná je nazývána jako vysvětlovaná či závislá proměnná. Další proměnné jsou nezávislé neboli vysvětlující.

Lineární regresní model

Lineární regresní model vychází ze vztahu definovaném lineární rovnicí ve tvaru 3.8.

$$Y_t = \beta_1 + \beta_2 X_{t1} + \beta_3 X_{t2} + \dots + \beta_k X_{tk} + \varepsilon_t, \quad (3.8)$$

kde Y_t je vysvětlovaná proměnná, X_{tk} jsou vysvětlující proměnné, β_k jsou koeficienty, neboli parametry a ε_t představuje reziduální složku.

Koeficient β_1 je takzvaný absolutní člen a jeho hodnota se v modelu nemění. Další koeficienty definují, jak se změní závislá proměnná, pokud nezávislá proměnná při koeficientu se změní o jednotku, za jinak neměnných podmínek. Reziduální složka zahrnuje vlivy, které nejsou v modelu explicitně uvedeny, chyby v měření ekonomických a finančních veličin a další jevy, které mají náhodný charakter a určitý dopad na proměnné, nelze je však do modelu zahrnout. Metody, které lze pro odhad jednotlivých parametrů lineárního regresního modelu použít, jsou:

- metoda nejmenších čtverců,
- metoda maximální věrohodnosti a
- zobecněná metoda momentu.

V aplikační části této práce bude použita metoda nejmenších čtverců, která je popsána v další podkapitole.

Metoda nejmenších čtverců

Metoda nejmenších čtverců je založena na minimalizaci součtu druhých mocnin odchylek hodnot vysvětlované proměnné od odhadnuté regresní přímky. Metodu lze zapsat rovnicí 3.9.

$$S = \sum_{t=1}^T [Y_t - (\beta_1 + \beta_2 X_{t1} + \beta_3 X_{t2} + \dots + \beta_k X_{tk})]^2 \quad (3.9)$$

Při aplikaci metody nejmenších čtverců pro dohad regresních parametrů, je dle Hančlová (2012) nutné, aby model splňoval následující předpoklady:

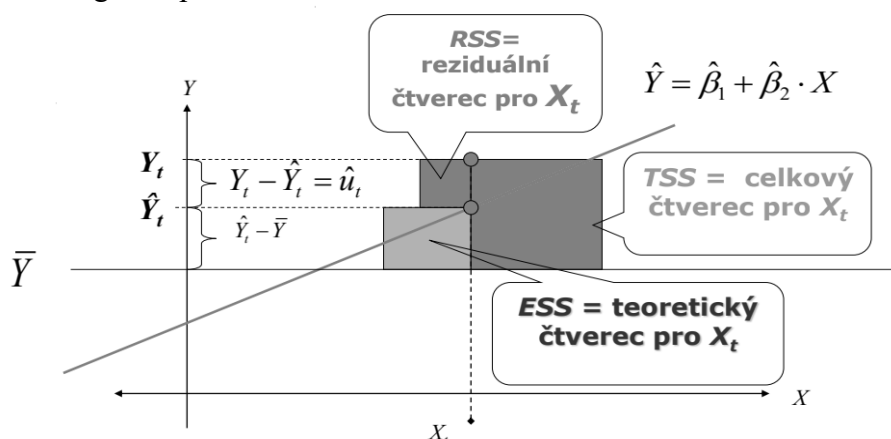
- lineární regresní model je lineární v parametrech,
- hodnota X_i není stochastická veličina,
- střední hodnota náhodné složky je nulová,
- variabilita náhodné složky je konstantní (je vyloučena heteroskedasticita),
- náhodná složka má normální rozdělení,
- náhodné složky jsou navzájem nekorelované (je vyloučena autokorelace),
- mezi proměnnými X_i neexistuje lineární vztah (je vyloučena multikolinearita),
- počet pozorování je větší, než počet parametrů modelu,
- regresní model je správně specifikován.

Hušek (2007) uvádí jako požadované vlastnosti odhadované funkce nestrannost a vydatnost. Nestrannost je charakterizována jako rovnost hodnoty odhadovaného parametru a jeho střední hodnoty. Vydatnost spočívá v tom, že ve srovnání s jinými odhadnutými funkcemi má menší nebo stejný rozptyl.

Koeficient determinace

Koeficient determinace slouží k posouzení shody hodnot lineárního regresního modelu s reálnými daty. Cipra (2013) koeficient determinace vysvětluje jako ukazatel toho, do jaké míry lze pomocí odhadnutého regresního modelu vysvětlit variabilitu proměnné Y kolem její střední hodnoty. Dále bude koeficient determinace označován jako R^2 (R Square). Stěžejním předpokladem je možnost rozložení úplného součtu čtverců na dvě složky, reziduální a vysvětlený (teoretický) součet čtverců. Vztah mezi těmito součty je znázorněn v následujícím obrázku 3.1.

Obrázek 3.1 Regresní přímka - rozklad čtverců



Zdroj: HANČLOVÁ, Jana. Ekonometrie: Jednoduchý lineární regresní model [přednáška]. Ostrava, VŠB-TU EKF, 1.10.2019.

Vzorce pro výpočet úplného, reziduálního a vysvětleného součtu čtverců lze odvodit z obrázku výše. Vzorce jsou znázorněny pomocí následujících třech rovnic 3.10, 3.11 a 3.12.

$$TSS = \sum_{t=1}^n (Y_t - \bar{Y})^2 \quad (3.10)$$

$$RSS = \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (3.11)$$

$$ESS = \sum_{t=1}^n (\hat{Y}_t - \bar{Y})^2 \quad (3.12)$$

Pomocí těchto dílčích vzorců lze již zapsat konečnou rovnici 3.13 pro výpočet koeficientu determinace R^2 .

$$R^2 = \frac{ESS}{TSS} = \frac{TSS - RSS}{TSS} = 1 - \frac{RSS}{TSS} \quad (3.13)$$

3.5 Verifikace modelu

Verifikace modelu představuje čtvrtou fází procesu ekonometrického modelování. Verifikace je rozdělena dle tří hledisek na statistickou, ekonometrickou a ekonomickou verifikaci. Verifikaci lze definovat jako ověření platnosti sestaveného modelu.

3.5.1 Statistická verifikace

Pomocí statistické verifikace dochází k ověření, zda je model i jeho jednotlivé parametry statisticky významné. V zásadě se používají dva statistické testy, studentův t-test a F-test. Pokud je ověřována statistická významnost jednotlivých parametrů je vhodnější použít t-test. Pro ověření významnosti modelu jako celku se obvykle využívá F-test. Pro statistické testování je vždy nutné si na počátku stanovit dvě hypotézy, hypotézu nulovou a alternativní. Dále pravidlo, dle kterého bude rozhodnuto o přijetí či nepřijetí nulové hypotézy na zvolené hladině významnosti. Nulová hypotéza H_0 má formu určitého výroku o vlastnosti jednoho nebo více parametrů modelu. Alternativní hypotéza H_1 má podobu výroku přesně opačného. Závěr statistického testování může mít dvě podoby, buď je nulová hypotéza přijata a výrok může být pravdivý nebo je nulová hypotéza zamítnuta a přijata hypotéza alternativní.

Studentův t-test

Hypotézy t-testu lze definovat následujícím způsobem dle rovnice 3.14. Přijetí hypotézy H_0 znamená, že regresní parametr je statisticky nevýznamný. Pokud je nulová hypotéza zamítnuta a přijata hypotéza alternativní, regresní parametr je statisticky významný. Dále je nutné stanovit testovací kritérium, na jehož základě bude rozhodnuto o přijetí či zamítnutí nulové hypotézy. Hodnota testovacího kritéria lze vyčíslit dle vztahu 3.15.

$$\begin{aligned}H_0: \beta_i &= 0, \\H_1: \beta_i &\neq 0\end{aligned}\tag{3.14}$$

$$t_{vyp} = \frac{\hat{\beta}_i - 0}{\hat{\sigma}_{\hat{\beta}_i}} \approx t_{df},\tag{3.15}$$

kde $\hat{\beta}_i$ je odhadnutá hodnota regresního parametru, $\hat{\sigma}_{\hat{\beta}_i}$ je odhadnutá hodnota směrodatné odchylky regresního parametru a t_{df} je Studentovo rozdělení pravděpodobnosti s parametry n, k , kde n je počet pozorování a k je počet parametrů, df udává stupeň volnosti Studentova rozdělení, který lze definovat jako rozdíl počtu pozorování a počtu regresních parametrů.

Jedním ze způsobů, jak určit, zda bude nulová hypotéza zamítnuta či nikoliv je porovnání vypočteného testovacího kritéria t_{vyp} s hodnotou kritickou, tzv. t_{krit} . Hodnotu t_{krit} lze stanovit pomocí funkce aplikace Excel $TINV(\alpha, df)$, kde α je zvolená hladina významnosti a df jsou stupně volnosti. V této práci, pokud nebude uvedeno jinak, bude vždy použita hladina významnosti 5%. Druhou možností, jak určit hodnotu t_{krit} , jsou statistické tabulky kritických hodnot, opět na základě α a df . Pokud je absolutní hodnota t_{krit} menší než absolutní hodnota t_{vyp} je nulová hypotéza zamítnuta a přijata hypotéza alternativní.

Druhé rozhodovací pravidlo je definováno na základě intervalu spolehlivosti. Zde je nutné stanovit $(1 - \alpha)$ procentní interval spolehlivosti odhadu parametru β_i . Následně bude zkoumáno, zda nulová hodnota parametru β_i leží uvnitř, nebo vně tohoto intervalu. Interval lze popsat následující rovnicí 3.16. Pokud se bude hodnota parametru nacházet vně intervalu, bude nulová hypotéza zamítnuta na hladině významnosti α .

$$\hat{\beta}_i - t_{krit} \hat{\sigma}_{\hat{\beta}_i} \leq \beta_i \leq \hat{\beta}_i + t_{krit} \hat{\sigma}_{\hat{\beta}_i}\tag{3.16}$$

Třetí způsob statistického testování pomocí t-testu je využití takzvané *p-hodnoty*, která je porovnávána s hodnotou α . Jestliže je *p-hodnota* menší než hodnota α , nulová hypotéza bude zamítnuta a přijata hypotéza alternativní. Tento způsob je z hlediska výpočtu nejsnadnější, tudíž i v praxi nejpoužívanější.

F-test

F-test je využíván pro testování statistické významnosti modelu jako celku. Výchozími podmínkami je opět normální rozdělení náhodné složky, stanovení testovací hladiny významnosti α a stanovení hypotéz H_0 a H_1 . O přijetí či zamítnutí nulové hypotézy lze rozhodnout na základě testovacího kritéria F_{vyp} nebo *p-hodnoty*.

Přijetí nulové hypotézy značí statistickou nevýznamnost modelu jako celku. V tomto případě jsou všechny parametry β_i současně rovny nule. Nenulové hodnoty nabývá pouze úrovně konstanta. Naopak zamítnutí nulové hypotézy připouští minimálně jeden nenulový parametr a tudíž, lze prohlásit model jako celek za statisticky významný. Tyto hypotézy jsou definovány vztahem 3.17

$$\begin{aligned} H_0: \beta_1 = \beta_2 = \dots \beta_n = 0 \\ H_1: \beta_1 \neq 0 \vee \beta_2 \neq 0 \vee \dots \vee \beta_n \neq 0 \end{aligned} \quad (3.17)$$

Pro rozhodnutí ohledně přijetí či nepřijetí nulové hypotézy lze využít dva postupy. Prvním je stanovení hodnoty F_{vyp} a porovnání s hodnotou kritickou. Kritickou hodnotu pro F-test lze získat pomocí funkce aplikace Excel FINV (α, df_1, df_2) nebo ze statistických tabulek kritických hodnot. Vzorec pro výpočet hodnoty F_{vyp} je následující:

$$F_{vyp} = \frac{ESS/df_1}{RSS/df_2} = \frac{ESS/(k-1)}{RSS/(n-k)} \sim F(df_1, df_2), \quad (3.18)$$

kde k je počet regresních parametrů, n je počet parametrů, df_1 a df_2 udává počet stupňů volnosti.

V případě že při porovnání hodnot F_{vyp} a F_{krit} , bude zjištěn kladný rozdíl, tedy že F_{vyp} je vyšší, nulová hypotéza bude zamítnuta ve prospěch alternativní.

Druhý způsob rozhodování o zamítnutí či přijetí je založen na porovnání hodnoty hladiny významnosti α a *p-hodnoty*. Pokud je *p-hodnota* vyšší, nulová hypotéza bude zamítnuta a přijata hypotéza alternativní.

3.5.2 Ekonometrická verifikace

Druhá forma verifikace je verifikace ekonometrická. Pomocí metod ekonometrické verifikace se ověřují podmínky nezbytné pro aplikaci ekonometrických metod. Součástí této podkapitoly bude popis metodiky pro testování autokorelace, heteroskedasticity, multikolinearity, normality reziduální složky a specifikace modelu.

Autokorelace

Autokorelace je vzájemná závislost posloupnosti hodnot náhodné složky odhadnutého modelu v čase. Jedna z podmínek pro aplikace metody nejmenších čtverců je vzájemná nezávislost, tedy vyloučení autokorelace. Možné příčiny autokorelace dle Huška (2007) jsou například zahrnutí chyb měření vysvětlované proměnné do náhodné složky modelu, použití různým způsobem zpožděných proměnných, chybná či nepřesná specifikace analytické formy modelu a další. Mezi důsledky Hančlová (2012) řadí například asymptotickou nevydatnost, jiný než minimální rozptyl a nestrané a nekonzistentní odhady regresních parametrů. Pokud v modelu existuje autokorelace, znamená to, že odhadnutý rozptyl náhodné složky je vychýlený a z toho vyplývá, že i odhad rozptylu regresního parametru je vychýlený. V tomto případě je testování hypotéz prostřednictvím intervalu spolehlivosti neúčinné ve smyslu ztráty vypovídací schopnosti.

Metod pro ověření autokorelace je několik. Lze použít několik grafických testů, například XY graf, liniový graf standardizovaných reziduí nebo parciální autokorelační graf. Pro testování autokorelace prvního řádu je vhodné využít Durbin- Watsonův test autokorelace.

Pro aplikaci Durbin- Watsonova testu je prvním krokem definování hypotéz. Hypotézy jsou formulovány následujícím způsobem:

$$\begin{aligned} H_0: \rho &= 0, \\ H_1: \rho &\neq 0. \end{aligned} \tag{3.19}$$

Pokud je přijata nulová hypotéza, znamená to, že autokorelace prvního řádu není významná. Zamítnutím nulové hypotézy se přijímá hypotéza alternativní, což znamená významnost autokorelace prvního řádu. Dle znaménka parametru lze odvodit zda autokorelace bude kladná nebo záporná. Pro výpočet hodnoty testovacího kritéria používá Hančlová (2012) a Cipra (2013) odlišné přístupy. Dle Hančlová (2012)

přibližná hodnota testovacího kritéria, pro tento test se obvykle užívá zkratka DW, lze vyčíslit dle následujícího vztahu:


$$DW \doteq 2(1 - \hat{\rho}). \quad (3.20)$$

Pokud se $\hat{\rho} = -1$, hodnota DW je přibližně 4, což značí velmi silnou negativní autokorelace. Hodnota $\hat{\rho} = 0$ znamená hodnotu DW rovnou 2 a nekorelovanost náhodné složky. Hodnota $\hat{\rho} = 1$ značí hodnotu DW koeficientu 0 a velmi silnou pozitivní autokorelaci prvního řádu. Cipra (2013) uvádí odlišný, složitější, vzorec pro výpočet testovacího kritéria DW, znázorněn rovnicí 3.21.

$$DW = \frac{\sum_{t=2}^T (\hat{\varepsilon}_t - \hat{\varepsilon}_{t-1})^2}{\sum_{t=2}^T \hat{\varepsilon}_t^2} \quad (3.21)$$

Podstatnou součástí Durbin- Watsonova testu je určení dvou kritických hodnot, d_L a d_U . Tyto kritické hodnoty jsou určeny na základě počtu pozorování a počtu vysvětlujících proměnných a lze je dohledat ve statistických tabulkách kritických hodnot. Testovací kritérium, DW koeficient, má d-rozdělení a může nabývat hodnot od 0 do 4. Rozhodovací pravidlo, kdy je nutné nulovou hypotézu přijmout či zamítnout je znázorněn v obrázku 3.1.

Obrázek 3.2 Závěry Durbinova- Watsonova testu



Zdroj: Hančlová, 2012

Pokud po provedení testů bude autokorelace v modelu potvrzena, je nutné ji odstranit nebo alespoň zmírnit. Existuje několik metod, Hančlová (2012) uvádí například vložení trendové proměnné, vložení zpožděné závislé proměnné nebo aplikaci Cochrane - Orcuttovy metody.

Heteroskedasticita

Druhá podmínka aplikace metody nejmenších čtverců je vyloučení heteroskedasticity. Jedná se o vlastnost rozptylu náhodné složky. Pokud je rozptyl náhodné složky heteroskedastický, znamená to, že není konečný a konstantní. Naopak homoskedasticita nastává, pokud je variabilita náhodné složky konečná a konstantní. Příčin vzniku heteroskedasticity uvádí například Hančlová (2012) nebo Hušek (2007) několik. Jedná se například o chybnou specifikaci modelu, nedůsledná analýza odlehklých hodnot, velké rozdíly v hodnotách průřezových dat nebo nevhodná transformace dat. V případě nezajištění homoskedasticity náhodné složky hrozí negativní dopady na odhady regresních parametrů a vlastnosti odhadovaných funkcí. Hančlová (2012) rozlišuje dopady heteroskedasticity dle toho, zda je v modelu využit malý nebo velký výběrový soubor. V případě malého výběrového souboru, za přítomnosti heteroskedasticity, jsou odhadnuté regresní parametry lineární a nevychýlené a rozptyl je zkreslený a nevydatný. Přítomnost heteroskedasticity u velkých výběrových souborů má za následek asymptotickou nestrannost, případně nevydatnost a konzistentnost odhadnutých regresních parametrů.

Pro testování homoskedasticity lze použít opět několik grafických testů a dále statistické testy, například Whiteův zobecněný test nebo Goelfeld- Quandtův test. Z grafických testů se nejčastěji používají grafy vývoje čtverců standardizovaných reziduí, takzvané scatter grafy. V grafu může být reziduální složka zobrazena v závislosti buď na jednotlivých nezávislých proměnných, nebo na závisle proměnné. Pro potvrzení homoskedasticity je důležité, aby v grafu byly splněny dvě podmínky. Zaprvé body znázorňující vývoj standardizované náhodné složky by měly ležet v intervalu $\langle 0; 1,96^2 \rangle$ a zadruhé body musí být rozmístěny náhodně, nesmí vykazovat na pohled zřetelný trend.

Statistický Whiteův test je dle Cipra (2013) jeden z nejpoužívanějších. Základem tohoto testu je vytvoření pomocného modelu, jenž je ovšem odvozen od modelu původního. Pomocí něhož je pak měřena závislost náhodné složky v kvadratickém tvaru na ostatních proměnných. Pokud je původní model ve tvaru rovnice 3.22, lze odvozený pomocný model definovat dle rovnice 3.23.

$$Y_t = \beta_1 + \beta_2 X_{t1} + \beta_3 X_{t2} + \varepsilon_t \quad (3.22)$$

$$\varepsilon_t^2 = \alpha_1 + \alpha_2 X_{t2} + \alpha_3 X_{t3} + \alpha_4 X_{t2}^2 + \alpha_5 X_{t3}^2 + \alpha_6 X_{t2} X_{t3} + u_t \quad (3.23)$$

Jako u každého statistického testu i zde je nutné nejprve nadefinovat hypotézy. Nulová hypotéza potvrzuje homoskedasticitu. Tedy potvrzuje nezávislost rozptylu náhodné složky na všech parametrech. Jediná přípustná závislost je mezi rozptylem náhodné složky a úrovní konstantou. Hypotéza alternativní potvrzuje přítomnost heteroskedasticity, tedy závislost rozptylu náhodné složky na alespoň jednom parametru. Hypotézy lze formulovat následovně:

$$H_0: \alpha_1 = \alpha_2 = \dots \alpha_n = 0,$$

$$H_1: \alpha_1 \neq 0 \vee \alpha_2 \neq 0 \vee \dots \vee \alpha_n \neq 0. \quad (3.24)$$

Druhým krokem je stanovení testovacího kritéria, kterým je zde chi-statistika (χ^2_{vyp}). Výpočet hodnoty tohoto kritéria je znázorněn následujícím vzorcem 3.25.

$$\chi^2_{vyp} = nR^2 \sim \chi^2_{df}, \quad (3.25)$$

kde χ^2_{vyp} je hodnota testovacího kritéria, R^2 koeficient determinace a df počet vysvětlujících proměnných v odhadnutém modelu metodou nejmenších čtverců.

Nakonec je nutné stanovit kritickou hodnotu, se kterou bude porovnána vypočtená hodnota testovacího kritéria. Kritickou hodnotu χ^2_{krit} lze stanovit pomocí aplikace MS Excel a funkce *CHIINV* (α , df), kde α je zvolená hladina významnosti a df jsou stupně volnosti. Pokud je hodnota testovacího kritéria nižší než hodnota kritická, je nulová hypotéza přijata a heteroskedasticita je v modelu vyloučena. Pokud by ale nulová hypotéza byla zamítnuta a přijata hypotéza alternativní, je nutné heteroskedasticitu odstranit nebo alespoň zmírnit. K odstranění heteroskedasticity lze využít například váženou metodu nejmenších čtverců, která pracuje s upravenými časovými řadami a transformovaným ekonometrickým modelem.

Multikolinearita

Multikolinearitu lze definovat jako silnou závislost mezi jednotlivými nezávislými proměnnými modelu. Problém multikolinearity spočívá v tom, že vysoká vzájemná závislost vede ke zkreslení a menší vypovídací schopnosti parametrů odhadnutého regresního modelu. Potvrzení neexistence multikolinearity je jedním z předpokladů aplikace lineárního regresního modelu a metody nejmenších čtverců. Multikolinearitu, případně sílu závislosti, lze určit na základě korelačních koeficientů a analýzy korelační matice. Jako příčiny multikolinearity Hušek (2007) uvádí podobný

vývoj proměnných a jejich přírůstků, neexperimentální charakter použitých dat, zahrnutí různě zpožděných proměnných a další.

Pokud je model sestaven tak, že obsahuje pouze jednu vysvětlující proměnnou, je multikolinearita ihned vyloučena. V případě modelu s více nezávislými proměnnými lze pro zjištění multikolinearity dle Hančlová (2012) využít korelační matici pro analýzu párové korelace, vícenásobný koeficient korelace nebo míru korelovanosti.

Základní pravidlo při analýze korelační matice je, že hodnota korelačního koeficientu dvou vysvětlujících proměnných by neměla být vyšší než 0,8. Pokud by byla vyšší, párová korelace by byla příliš silná, což by znamenalo i silnou multikolinearitu.

Pro přesnější určení vícenásobné lineární závislosti lze využít vícenásobný koeficient korelace. Tato metoda využívá koeficient determinace $R_{přívodní}^2$ odhadnutého regresního modelu a nové koeficienty determinace regresních modelů $R_{X_i}^2$, definovaných vždy jako modely jednotlivých nezávislých proměnných, přičemž v každém modelu se jedna nezávislá proměnná stane závislou. Tyto modely lze dle Hančlová (2012) vyjádřit vztahem 3.26.

$$X_{i,t} = \alpha_{i1} + \alpha_{i2}X_{t,2} + \dots + \alpha_{i,i-1}X_{t,i-1} + \alpha_{i,i+1}X_{t,i+1} + \dots + \alpha_{ik}X_{t,k} + \varepsilon_{it} \quad (3.26)$$

Nové koeficienty determinace jsou následně využity pro výpočet hodnoty testovacího kritéria F-testu, kterou lze vyjádřit vztahem 3.27.

$$F_{vyp} = \frac{R_{X_i}^2}{1-R_{X_i}^2} \cdot \frac{n-k+1}{k-2} \sim F(k-1, n-k) \quad (3.27)$$

Nulová hypotéza pro tento model je formulována jako neexistence významné multikolinearity v modelu. Alternativní hypotéza naopak připouští výskyt významné multikolinearity v modelu. Testovací kritérium je porovnáno s kritickou hodnotou $F_{krit}(k-1, n-k)$ a pokud je F_{vyp} větší než F_{krit} je nulová hypotéza zamítnuta a přijata hypotéza alternativní. Tímto je tedy potvrzen výskyt multikolinearity v modelu. Pokud je potvrzena multikolinearita je nutné ji odstranit nebo alespoň zmírnit. Dle Hušek (2007) zmírnění multikolinearity lze dosáhnout zvětšením rozsahu výběru, využití dodatečné informace ve formě apriorních omezení nebo pouze odstranit vysvětlující proměnnou, která zapříčiňuje multikolinearitu.

Specifikace modelu

Hančlová (2012) považuje správnou specifikaci modelu jako jeden z nejdůležitějších předpokladů pro uplatnění metody nejmenších čtverců. Testováním správné specifikace je ověřováno, zda model obsahuje všechny podstatné proměnné, neobsahuje nevýznamné proměnné nebo zda je zvolena správná funkční forma modelu. Jednou z možných metod, jak testovat správnou specifikaci, je testování pomocí Ramseyho RESET testu.

Nejprve je nutné opět stanovit hypotézy. Nulová hypotéza je formulována jako výrok o správné specifikaci regresního modelu. Alternativní hypotéza má formu výroku, kdy regresní model není správně specifikován. Ramseyho RESET test staví na předpokladu, že pokud dojde k opomenutí významné proměnné nebo zvolení špatné funkční formy, je tato informace zahrnuta v reziduální složce. Při testování je do původního modelu doplněna druhá mocnina predikované proměnné a následně i třetí mocnina. Dále je stanoven koeficient determinace nového modelu R_{new}^2 . Testovací kritérium pro rozhodnutí o přijetí či nepřijetí nulové hypotézy lze vyčíslit dle vztahu 3.28.

$$F_{vyp} = \frac{R_{new}^2 - R_{původni}^2 / df_1}{1 - R_{new}^2 / df_2} \sim F(df_1, df_2), \quad (3.28)$$

kde df_1 je počet přidanych proměnných v novém modelu a df_2 je počet pozorování ponížen o počet regresních parametrů nového modelu.

Ve statistických tabulkách kritických hodnot lze opět dohledat kritickou hodnotu pro tento test pro zvolenou hladinu významnosti α . Pokud je kritická hodnota F_{krit} menší než F_{vyp} je nulová hypotéza zamítnuta ve prospěch alternativní. Regresní model není v tomto případě správně specifikován a je nutné následně zvolit takové úpravy, aby předpoklad správné specifikace byl splněn.

Normalita reziduální složky

Normalita reziduální složky je posledním předpokladem k aplikaci vytvoření lineárního regresního modelu za využití metody nejmenších čtverců. Náhodná složka by měla mít normální rozložení pro všechna t . Pro testování normality lze využít jak grafické, tak neparametrické testy normality.

Grafická analýza je založena na analýze histogramu rozdělení četností, který je porovnáván s Gaussovou křivkou nebo lze využít takzvané P-P a Q-Q grafy. Mezi

neparametrické testy využitelné pro testování normality lze zařadit například Kolmogorov- Smirnov test, Jargue- Bera test nebo test dobré shody. Všechny testy mají společnou formulaci nulové hypotézy. Nulová hypotéza je formulována jako potvrzení normálního rozložení náhodné složky.

Kolmogorov- Smirnov test je založen na rozdílu mezi teoretickou a empirickou distribuční funkcí. Postup aplikace tohoto testu ve své publikaci popisuje Hančlová (2012) následovně. Prvním krokem aplikace testu je stanovení nulové a alternativní hypotézy.

H_0 : Distribuční funkce rozdělení náhodného výběru $F_n(x)$ odpovídá teoretické distribuční funkci $\phi(x)$.

H_1 : Distribuční funkce rozdělení náhodného výběru $F_n(x)$ neodpovídá teoretické distribuční funkci $\phi(x)$.

Druhým krokem je odhad výběrových reziduí pomocí metody nejmenších čtverců a výpočet empirické distribuční funkce $F_n(x)$. Následně je v každé i - té třídě, kde $i = 1, 2, \dots, m$, vypočteny absolutní pozitivní (D_i^+) a negativní (D_i^-) rozdíly teoretické a empirické distribuční funkce vzhledem k vrcholu schodu empirické distribuční funkce a vzhledem k patě schodu empirické distribuční funkce dle vztahů 3.29 a 3.30 definovaných níže.

$$D_i^+ = F_n(x_{i+1}) - \Phi(x), \quad (3.29)$$

$$D_i^- = F_n(x_{i+1}) - \Phi(x). \quad (3.30)$$

Vztah 3.31 znázorňuje vzorec pro výpočet největšího rozdílu mezi kladnými a zápornými odchylkami. Testovací statistika z_{vyp} lze vyčíslit dle vztahu 3.32.

$$D = \max_i \{D_i^+, |D_i^-|\}. \quad (3.31)$$

$$z_{vyp} = \sqrt{n} \cdot D \sim N(0; 1). \quad (3.32)$$

Testovací kritérium je následně porovnáváno s kritickou hodnotou. Kritickou hodnotu lze zjistit ze statistických tabulek na základě zvolené hladiny významnosti α . Pokud je testovací kritérium větší než kritické, je nulová hypotéza zamítnuta a přijata hypotéza alternativní. V takovém případě distribuční funkce rozdělení náhodného neodpovídá teoretické distribuční funkci, a tudíž rozdělení náhodné složky není normální. Alternativní postup rozhodování je na základě porovnání dané hladiny

významnosti a *p-hodnoty*. Pokud je *p-hodnota* nižší než α , H_0 nulová hypotéza zamítnuta ve prospěch hypotézy alternativní.

3.5.3 Ekonomická verifikace

Poslední částí verifikace modelu je verifikace ekonomická. Výstupem je interpretace odhadnutých regresních parametrů i celého modelu a zhodnocení celkové vypovídací schopnosti a využitelnosti modelu v praxi. Vychází se ze základních ekonomických principů a omezení. Základem je ekonomická interpretace odhadnutých regresních parametrů, hodnocení očekávání a konkrétních výsledných hodnot dosažených odhadnutým modelem. Porovnávána jsou především znaménka odhadnutých koeficientů a vliv jednotlivých parametrů na vysvětlovanou proměnnou. V případě zjištění významného nesouladu mezi teoretickým očekáváním stanoveným na počátku a výsledným modelem, je nutné provést revizi jednotlivých kroků ekonometrického modelování a zjistit příčiny jednotlivých rozdílů. Dle Hušek (2007) jsou možné důvody odlišností neadekvátnost dat a nesplnění předpokladů nutných pro využití zvolených metod.

Pokud jsou v průběhu jakékoliv verifikace zjištěny pochybnosti o vypovídací schopnosti a správnosti zvoleného modelu, je nutná zpětná korekce v předcházejících fázích ekonometrického modelování.

3.6 Využití odhadnutého modelu

Poslední fází ekonometrického modelování je využití výstupů odhadnutého modelu pro zkoumání analyzovaného jevu, simulace, predikce do budoucna a optimalizaci řízení. Tento krok je možný pouze za předpokladu správnosti předcházejících výsledků na základě důsledného přezkoumání. Způsob využití je odvozen od hlavního cíle modelování, proč byl vlastně regresní model odhadován. Hančlová (2012) uvádí tři základní oblasti možnosti využití odhadnutého modelu. První je analýza vývoje a chování zkoumaného ekonomického jevu, druhá oblast zahrnuje predikci vývoje zkoumané veličiny do budoucna a třetí oblastí je využití pro optimální řízení hospodářské politiky, zejména v oblasti simulace scénářů a jejich dopadů.

4 Zhodnocení vlivu vybraných faktorů na akciové environmentální indexy

Čtvrtá kapitola je zaměřena na aplikaci metod popsaných ve třetí kapitole na získaných datech vybraných akciových indexů a zvolených faktorů. V této podkapitole budou provedeny odhady jednofaktorových lineárních regresních modelů metodou nejmenších čtverců a následně nejvhodnějších vícefaktorových modelů.

Nejprve jsou proměnné charakterizovány, zejména jejich vývoj v čase. Následně byla provedena ekonomická, matematická a ekonometrická formulace modelu. V rámci následné analýzy dat byla vytvořena popisná statistika, analýza chybějících, odlehlých a extrémních hodnot a korelační analýza. Proměnné byly dle výsledků náležitě upraveny. Poté již bylo možné formulovat odhady jednofaktorových regresních modelů pomocí metody nejmenších čtverců. Posledním krokem ekonometrického modelování je statistická, ekonometrická a ekonomická verifikace. V kapitolách 4.7 a 4.8 jsou formulovány vícefaktorové modely.

Odhad modelů byl proveden v aplikaci IBM SPSS Statistics, kritické hodnoty statistických testů a některé grafické analýzy byly provedeny v aplikaci Microsoft Excel.

Hodnoty jednotlivých indexů byly získány na stránkách společnosti S&P Global. Hodnoty koncentrace oxid uhličitýho zveřejňuje na svých stránkách nadace spadající pod organizaci NASA. Hodnoty koncentrace metanu jsou dostupné na stránkách institutu The 2^o Institute. Objem prodeje elektromobilů a plug-in hybridů ve Spojených Státech zveřejňuje na svých stránkách společnost InsideEVs. Podíl energie z obnovitelných zdrojů v zemích OECD pravidelně každý měsíc zveřejňuje formou elektronické publikace společnost International Energy Agency.


4.1 Charakteristika vybraných proměnných

V následujících modelech byly jako vysvětlované proměnné postupně použity tři různé akciové indexy skupiny S&P Global, konkrétně S&P Global Water Index, S&P Global Eco Index a S&P Global Clean Energy Index. Hodnoty těchto indexů zveřejňuje na svých internetových stránkách společnost S&P Global. Jako vysvětlující proměnné

figuruje 4 vybrané faktory úzce navázány na oblast životního prostředí. Jsou použity měsíční hodnoty v intervalu od ledna 2011 do září 2019.

První vysvětlovanou proměnnou je akciový index S&P Global Water Index. Hodnota indexu je vyjádřena v bodech. Na počátku byla stanovena základní hodnota indexu 1000 bodů. V obrázku 4.1 lze pozorovat pozvolný rostoucí trend indexu ve sledovaném období 2011 až 2019. Křivka však nebyla rostoucí vždy, pokles indexu byl zaznamenán v období květen 2014 až leden 2016 a následně po celý rok 2018. Hodnoty indexu se ve sledovaném období pohybují v rozmezí od 2000 do 4200 bodů. Hodnota indexu od jeho založení značně vzrostla, což značí pozitivní hospodářský rozvoj v oblasti vodohospodářství.


Obrázek 4.1 Vývoj S&P Global Water Indexu



Zdroj: vlastní zpracování

Druhou vysvětlovanou proměnnou a druhým indexem je S&P Global Clean Energy Index. Hodnota indexu je opět vyjádřena v bodech a stejná je i základní hodnota indexu 1000 bodů. Obrázek 4. 2 znázorňuje vývoj indexu v letech 2011 až 2019. Oproti předchozímu indexu nelze zde stanovit jasný trend. Je zde značný propad po celý rok 2011 až do poloviny roku 2012. Hodnota indexu pak mírně rostla, ale za sledované období se již nikdy nevrátila na úroveň z počátku roku 2011. Hodnota indexu většinu období kolísala kolem 600 bodů, přičemž bazální hodnota indexu byla 1000 bodů. Z vývoje lze usuzovat, že v oblasti obnovitelných zdrojů energie došlo ke značné krizi na počátku roku 2011.


Obrázek 4.2 Vývoj S&P Global Clean Energy Indexu



Zdroj: vlastní zpracování

Třetí a poslední vysvětlovanou proměnnou je index S&P Global Eco. Bazální hodnota tohoto indexu byla stanovena na 100 bodů. Vývoj hodnoty indexu v analyzovaném období leden 2011 až září 2019 znázorňuje obrázek 4.3. Vývoj je velmi podobný indexu S&P Global Water, ovšem jeho růst není tak rychlý. Zatímco poslední hodnota indexu S&P Global Water je více než čtyřnásobná oproti základní hodnotě, zde je to pouze dvojnásobek. Vývoj v posledních měsících sledovaného období je však velmi pozitivní. Malý pokles hodnot lze sledovat na přelomu let 2011/2012 a v druhé polovině roku 2015.


Obrázek 4.3 Vývoj S&P Global Eco Indexu



Zdroj: vlastní zpracování

Vysvětlujícími proměnnými jsou hodnoty koncentrace CO_2 a CH_4 v atmosféře, prodej plug-in hybridů a elektromobilů ve Spojených státech a podíl energie z obnovitelných zdrojů ve členských státech OECD. Hodnota koncentrace CO_2 v atmosféře je udávána v jednotkách ppm (parts per million). Vývoj od počátku roku 2011 je znázorněn na obrázku 4.4. Trend je konstantně rostoucí, bez výrazných období poklesu. Časová řada hodnot koncentrace byla velmi ovlivněna sezónností, tudíž v grafu jsou použity už hodnoty sezónně očištěné.


Obrázek 4.4 Koncentrace CO_2 v atmosféře



Zdroj: vlastní zpracování

Druhou vysvětlující proměnnou je koncentrace CH_4 v atmosféře. Hodnoty jsou uváděny v jednotkách ppb (parts per billion). Časová řada hodnot musela být očištěna od vlivu sezónnosti. Trend je po celé sledované období rostoucí, pouze s mírnými občasnými poklesy. Vývoj je znázorněn na obrázku 4.5.


Obrázek 4.5 Koncentrace CH_4 v atmosféře



Zdroj: vlastní zpracování

Další vysvětlující proměnnou je objem prodejů plug-in hybridů a elektromobilů ve Spojených státech. V roce 2011 bylo toto odvětví v začátcích a měsíční prodeje se pohybovaly řádově ve stovkách kusů. Během sledovaného období, které je relativně krátké, se objem prodejů mnohonásobně zvýšil a v posledních letech se pohybuje již v desítkách tisíc. Nejvyšších hodnot bylo dosaženo na konci roku 2018. Vývoj objemů prodejů je znázorněn v následujícím obrázku 4.6.

Obrázek 4.6 Prodej plug-in hybridů a elektromobilů v USA



Zdroj: vlastní zpracování

Poslední vysvětlující proměnnou je podíl energie z obnovitelných zdrojů na celkově vyrobené energii v členských státech OECD. Hodnoty jsou na obrázku 4.7 uvedeny v procentech. I tato časová řada již pracuje s hodnotami očištěnými od vlivu sezónnosti. Celkový trend je opět rostoucí, ovšem volatilita je větší než u hodnot koncentrace CO_2 a CH_4 .

Obrázek 4.7 Podíl energie z obnovitelných zdrojů v členských státech OECD



Zdroj: vlastní zpracování

4.2 Formulace modelu

Formulace modelů ze tří hledisek, ekonomického, matematického a ekonometrického, je první fází procesu ekonometrického modelování. V rámci ekonomické formulace jsou popsány jednotlivé proměnné a jejich předpokládané vzájemné vazby. Tyto vztahy jsou následně převedeny do rovnic matematického modelu. Ekonometrický model je vytvořen přidáním náhodné proměnné do modelu matematického.

4.2.1 Ekonomická formulace modelu

Modely sestavovány v této práci jsou zaměřeny na oblast akciových indexů vázaných na životní prostředí. Cílem práce je zjištění existence či neexistence vzájemného vztahu mezi environmentálními akciovými indexy a reálnými ukazateli vývoje životního prostředí. Jak z ekonomického tak z hlediska environmentálního, při zhoršujících se faktorech vývoje životního prostředí by měl být kladen větší důraz na jeho ochranu a tedy investice k ochraně životního prostředí by měly růst. Růst investic by tak měl zvyšovat i hodnoty firem zahrnutých v bázích vybraných indexů, což by dále mělo zapříčinit pozitivní vývoj jednotlivých indexů. Tyto indexy a jejich vztah k životnímu prostředí je popsán v druhé kapitole této práce.

Vysvětlovanými proměnnými jsou postupně tři indexy ze skupiny S&P Global, konkrétně S&P Global Clean Energy Index, S&P Global Water Index a S&P Global Eco Index. V modelu je uvažováno s hodnotami indexů v bodech, přičemž původně stanovená základní hodnota všech indexů byla 1000 bodů. U indexu S&P Global Eco proběhlo ale přetransformování hodnoty indexu a bazální hodnota byla nakonec stanovena na 100 bodů. Všechny indexy se řídí striktními pravidly, jaké společnosti a za jakých podmínek mohou být obsaženy v jejich bázi. Tyto pravidla se zaměřují zejména na oblast ekologicky šetrného přístupu ve výrobě, aktivit pro podporu ochrany životního prostředí a investic do rozvoje technologií v tomto odvětví. Index S&P Global Eco je nejvíc obecný, další dva jsou úžeji zaměřené na ekologické technologie v oblasti výroby elektrické energie a hospodaření s vodou. Z podstaty skladby indexů je zřejmá úzká vazba na vývoj například technologií využívající obnovitelné zdroje ale také na obecné ukazatele vývoje životního prostředí jako jsou například uvolňované emise oxidu uhličitého.

Značným omezením pro výběr vhodných vysvětlujících proměnných byla nutnost dat s měsíční frekvencí. U mnoha vhodných faktorů je jejich vývoj sledován pouze na roční bázi. I přesto pro tuto práci byly vybrány čtyři výchozí vysvětlující proměnné s předpokládaným vztahem k závislé proměnné, tedy zvoleným akciovým indexům. První nezávislou proměnnou je vývoj úrovně CO_2 v atmosféře. Emise oxidu uhličitého a jeho koncentrace je veřejností přijímána jako univerzální ukazatel vývoje životního prostředí a také globálního oteplování. Právě tento chemický prvek je často laicky označován za hlavního viníka globálního oteplování. Pokud jeho koncentrace v atmosféře stoupá, měly by se také zvyšovat investice firem do snižování emisí a vývoje nových, šetrnějších technologií. Druhým faktorem a vysvětlující proměnnou je koncentrace metanu v atmosféře. Zvyšující se počet molekul v atmosféře tohoto prvku v posledních letech je rovněž s vysokou pravděpodobností zapříčiněn vývojem průmyslové produkce a lidské činnosti. I zde, zvyšující se koncentrace by měla posílit snahy ve vývoji účinnějších technologií, zvýšit investice a zájem společnosti o tuto oblast. Třetí faktor, podíl energie z obnovitelných zdrojů v zemích OECD, je více zaměřen na Index S&P Global Clean Energy, určitý vztah k dalším indexům ale rovněž nelze vyloučit. Rostoucí podíl energie z obnovitelných zdrojů je určitě nezbytný aspekt budoucího vývoje tohoto odvětví. Firmy, které jej budou respektovat a podporovat jeho další rozvoj tak budou posilovat svou pozici na trhu. Posledním faktorem je prodej elektromobilů a plug-in hybridů ve spojených státech. Rozvoj tohoto odvětví automobilového průmyslu odráží snahu mnoha firem omezit spalovací motory a postupně je nahradit jejich ekologičtější variantou.

Obecná ekonomická formulace jednofaktorových modelů pro jednotlivé nezávislé proměnné jsou znázorněny následujícími rovnicemi 4.1, 4.2, 4.3. Rovnice charakterizují předpokládaný vztah vysvětlujících proměnných a všech tří indexů.

$$W_t = f(\text{CO}_2_t^+, \text{CH}_4_t^+, s_t^+, \text{RE}_t^+), \quad (4.1)$$

$$E_t = f(\text{CO}_2_t^+, \text{CH}_4_t^+, s_t^+, \text{RE}_t^+), \quad (4.2)$$

$$\text{CE}_t = f(\text{CO}_2_t^+, \text{CH}_4_t^+, s_t^+, \text{RE}_t^+), \quad (4.3)$$

kde W_t je hodnota Water indexu, E_t je hodnota Eco Indexu, CE_t je hodnota Clean Energy Indexu, CO_2 je hladina oxidu uhličitého v atmosféře, CH_4 je hladina metanu v atmosféře, s je objem prodejů elektromobilů a plug-in hybridů ve Spojených státech a RE je podíl energie z obnovitelných zdrojů v zemích OECD.

4.2.2 Matematická formulace modelu

Matematická formulace je popsána v rovnicích 4.4, 4.5 a 4.6. Rovnice jsou specifikovány pro jednotlivé indexy. Jednofaktorové modely mají tvar lineární rovnice, kde závislá proměnná je index a nezávislá proměnná vždy jeden z faktorů.

$$W_t = \beta_1 + \beta_2 X_t \quad (4.4)$$

$$E_t = \beta_1 + \beta_2 X_t \quad (4.5)$$

$$CE_t = \beta_1 + \beta_2 X_t \quad (4.6)$$

kde CE_t je Clean Energy Index, W_t je Water Index, E_t je Eco Index, X_t zastupuje jednotlivé nezávislé proměnné, β_1 je úrovněová konstanta a β_2 je regresní koeficient.

4.2.3 Ekonometrická formulace modelu

Při ekonometrické formulaci do modelu zakomponována náhodná složka dle rovnice 3.8. Nyní jsou sestaveny rovnice jednofaktorového stochastického regresního modelu pro všechny tři indexy a všechny nezávislé proměnné.

$$CE_t = \beta_1 + \beta_2 CO_{2t} + \varepsilon_t \quad (4.7)$$

$$CE_t = \beta_1 + \beta_2 CH_{4t} + \varepsilon_t \quad (4.8)$$

$$CE_t = \beta_1 + \beta_2 S_t + \varepsilon_t \quad (4.9)$$

$$CE_t = \beta_1 + \beta_2 RE_t + \varepsilon_t \quad (4.10)$$

$$W_t = \beta_1 + \beta_2 CO_{2t} + \varepsilon_t \quad (4.11)$$

$$W_t = \beta_1 + \beta_2 CH_{4t} + \varepsilon_t \quad (4.12)$$

$$W_t = \beta_1 + \beta_2 S_t + \varepsilon_t \quad (4.13)$$

$$W_t = \beta_1 + \beta_2 RE_t + \varepsilon_t \quad (4.14)$$

$$E_t = \beta_1 + \beta_2 CO_{2t} + \varepsilon_t \quad (4.15)$$

$$E_t = \beta_1 + \beta_2 CH_{4t} + \varepsilon_t \quad (4.16)$$

$$E_t = \beta_1 + \beta_2 S_t + \varepsilon_t \quad (4.17)$$

$$E_t = \beta_1 + \beta_2 RE_t + \varepsilon_t \quad (4.18)$$

kde ε_t je náhodná složka, CO_2 je hladina oxidu uhličitého v atmosféře, CH_4 je hladina metanu v atmosféře, s je objem prodejů elektromobilů a plug-in hybridů ve Spojených státech a RE je podíl energie z obnovitelných zdrojů v zemích OECD. Dle předpokladů popsaných výše se očekává u všech rovnic kladný regresní koeficient β_2 .

4.3 Analýza dat

Data v této práci představují hodnoty tří akciových indexů, hodnoty koncentrace oxidu uhličitého a metanu v atmosféře, procentuální podíl energie z obnovitelných zdrojů v zemích OECD a objem prodaných elektromobilů a plug-in hybridů v USA. Nejprve byla vytvořena popisná statistika se základními charakteristikami, jako je maximum, minimum, počet pozorování, průměr a rozptyl. Časové řady, které nebyly očištěny o sezónnost, bylo nutné dekomponovat a sezónnost odstranit. Dále byly analyzovány chybějící, odlehlé a extrémní hodnoty, které bylo třeba později nahradit. Pomocí korelační matice byla provedena korelační analýza a závěrem také regresní analýza.

4.3.1 Popisná statistika

V rámci popisné statistiky byl zjištěn počet pozorování, dále hodnoty minima a maxima, hodnota průměru a rozptylu. U všech proměnných je počet pozorování shodných 105, což představuje hodnoty za 105 po sobě jdoucích měsíců. Deskriptivní statistika je znázorněna v tabulce 4.1. Hodnoty byly zjištěny pomocí programu SPSS.

Tabulka 4.1 Popisná statistika

		počet pozorování	maximum	minimum	průměr	rozptyl
Indexy	W	105	4188,49	2082,07	3112,53	343568,95
	E	105	241,56	129,73	175,75	756,67
	CE	105	1149,16	408,12	629,95	20986,17
Faktory	CO ₂	105	414,66	389,00	401,11	43,94
	CH ₄	105	1870,50	1795,80	1831,87	455,73
	s	105	49,90	0,35	12,97	103,57
	RE	105	0,29	0,17	0,22	0,001

Zdroj: vlastní zpracování

Množství dat je klíčový faktor pro vytvoření kvalitního regresního modelu. Model pracuje se 105 hodnotami u všech proměnných. Index Clean Energy dosahuje maximálních hodnot na počátku sledovaného období. U dvou dalších indexů jsou maxima naopak na konci sledovaného období. Největší rozptyl byl zjištěn u Water Indexu, jehož průběh se značně liší od vývoje Water a Eco Indexu. U vysvětlujících faktorů má největší rozptyl hodnota koncentrace metanu. Všechny vybrané faktory byly minimální na počátku sledovaného období. Hodnoty koncentrace metanu, oxidu uhličitého a podílu energie z obnovitelných zdrojů byly maximální na konci sledovaného období. Objem prodeje elektromobilů a plug-in hybridů byl nejvyšší v prosinci roku 2018.

4.3.2 Analýza chybějících, odlehlých a extrémních hodnot

Analýza chybějících, odlehlých a extrémních hodnot byla provedena pomocí box-plot grafů jednotlivých proměnných. Tyto grafy jsou součástí Přílohy 2. Časové řady všech proměnných byly kompletní, a tudíž nebylo nutné doplňovat chybějící hodnoty. Extrémní a odlehlé hodnoty byly zjištěny v časové řadě indexu Clean Energy a faktoru objemu prodeje elektromobilů a plug-in hybridů. Kompletní analýzu extrémních a odlehlých hodnot znázorňuje tabulka 4.2.

Tabulka 4.2 Počet odlehlých a extrémních hodnot

	W	E	CE	CO ₂	CH ₄	s	RE
odlehlé hodnoty	0	0	3	0	0	6	0
extrémní hodnoty	0	0	4	0	0	1	0

Zdroj: vlastní zpracování

Odlehlé hodnoty lze pro potřeby ekonometrického modelování v časové řadě zachovat. Extrémní hodnoty je nutné použitím vhodné metody nahradit. Extrémní hodnoty byly zjištěny u proměnné objemu prodeje a indexu Clean Energy. U proměnné objem prodeje byla extrémní hodnota nahrazena metodou průměru dvou sousedních hodnot. Metoda je vhodná za předpokladu umístění extrémní hodnoty uprostřed časové řady, což zde je splněno. U indexu bylo nutné použít jinou metodu nahrazení, jelikož extrémní hodnoty se nacházejí na začátku časové řady, konkrétně druhá až pátá pozice. Extrémní hodnoty v tomto případě byly nahrazeny pomocí metody lineární interpolace. V následujících kapitolách byly použity časové řady s již nahrazenými extrémními hodnotami.

4.3.3 Korelační analýza

V rámci korelační analýzy byla sestavena korelační matice obsahující Pearsonův korelační koeficient a dále grafy pro analýzu křížové korelace. Pearsonův korelační koeficient udává sílu vzájemné závislosti mezi dvěma proměnnými. Znaménko korelačního koeficientu značí, zda jde o pozitivní nebo negativní závislost. V analýze byly použity již sezónně očištěné časové řady proměnných koncentrace CO₂ (CO2_SAS), CH₄ (CH4_SAS) a podílu energie z obnovitelných zdrojů (RE_SAS) a také časové řady očištěné od extrémních hodnot (CE_LINT, s_MEAN). Korelační koeficient mezi závislou a nezávislými proměnnými by měl mít co nejvyšší hodnotu, naopak korelační koeficient mezi jednotlivými nezávislými proměnnými by měl být co nejnižší. Silná vzájemná závislost mezi vysvětlujícími faktory vede k problému multikolinearity, který je pro potřeby ekonometrického modelování nežádoucí. V následující tabulce 4.3 jsou znázorněny Pearsonovy korelační koeficienty. V Příloze 3 jsou kompletní korelační matice i s hodnotami Sig., které udávají statistickou významnost.

Tabulka 4.3 Korelační matice

	W	E	CE_LINT	CO2_SAS	CH4_SAS	s_MEAN	RE_SAS
W	1	0,955**	-0,121	0,948**	0,937**	0,836**	0,911**
E	0,955**	1	0,096	0,895**	0,895**	0,804**	0,875**
CE_LINT	-0,121	0,096	1	-0,290**	-0,257**	-0,230*	-0,281**
CO2_SAS	0,948**	0,895**	-0,290**	1	0,993**	0,861**	0,958**
CH4_SAS	0,937**	0,895**	-0,257**	0,993**	1	0,853**	0,952**
s_MEAN	0,836**	0,804**	-0,230*	0,861**	0,853**	1	0,832**
RE_SAS	0,911**	0,875**	-0,281**	0,958**	0,952**	0,832**	1

Zdroj: vlastní zpracování

Hvězdičky u některých hodnot značí statistickou významnost. Dvě hvězdičky vyjadřují statistickou významnost na hladině významnosti 0,01, jedna hvězdička statistickou významnost na hladině významnosti 0,05. Hodnoty korelačních koeficientů mezi CE_LINT a jednotlivými faktory jsou záporné, tudíž je zde potvrzen negativní vztah. Zbylé hodnoty v tabulce jsou kladné, tudíž mezi indexy W a E a vysvětlujícími faktory je vztah kladný. Každá hodnota je také statisticky významná na hladině významnosti 0,01 až na jedinou výjimku, kdy hladina významnosti je pouze 0,05. Nejnižší hodnoty korelačních koeficientů jsou v řádku Indexu Clean Energy. Vůbec nejslabší vztah je mezi tímto indexem a proměnnou s_MEAN, kde hodnota činí jen -

0,23. Nejsilnější vztah má s nezávislými proměnnými Water Index, kdy pouze jednou není hodnota vyšší než 0,9 a vždy jde o statisticky významnou závislost na hladině významnosti 0,01.

Hodnota korelačních koeficientů mezi jednotlivými nezávislými proměnnými by měla být co nejnižší, v literatuře se nejčastěji uvádí nižší než 0,8. Tuto podmínku nesplňuje jediná hodnota korelačního koeficientu nezávislých proměnných, a tudíž je zde velká pravděpodobnost silné multikolinearity v případě vytvoření vícefaktorového modelu. Jedním z řešení je vytvoření pouze jednofaktorových modelů, které jsou konstruovány v následující kapitole. Nejsilnější vzájemná závislost vůbec je pak mezi proměnnými CO2_SAS a CH4_SAS, z toho důvodu je vhodné zvážit vyřazení jedné z těchto proměnných z vícefaktorového modelu.

Pomocí křížové korelace lze analyzovat významnost β koeficientů a jejich znaménko, statistickou významnost dat a také zpoždění časové řady. Analýza je provedena pomocí sloupcových grafů se zvýrazněnou horní a dolní hranicí konfidenčního intervalu. Grafy jsou součástí Přílohy 3. Pro Water Index a Eco Index nebylo zjištěno ani u jednoho vysvětlujícího faktoru zpoždění. V každém grafu je nejvyšší sloupec v čase 0 a všechny sloupce přesahují horní hranici konfidenčního intervalu, což znamená statistickou významnost. Pro Clean Energy Index bylo zjištěno časové zpoždění u všech faktorů. Proměnná CO2_SAS, CH4_SAS a s_MEAN předbíhá index o sedm období (CO2_SAS_{t+7}, CH4_SAS_{t+7} a s_MEAN_{t+7}). Proměnná RE_SAS předbíhá index o dvě období (RE_SAS_{t+2}). Po zjištění těchto skutečností byla sestavena nová korelační matice. Korelační koeficienty jsou znázorněny v tabulce 4.4, celá korelační matice i s hodnotami statistické významnosti Sig. jsou v Příloze 3. V matici došlo pouze k mírnému nárůstu korelačních koeficientů mezi Indexem Clean Energy a jednotlivými faktory. Hodnoty koeficientů jsou opět záporné. U všech byla opět potvrzena statistická významnost na hladině významnosti 0,01 nebo 0,05. Korelační koeficienty mezi jednotlivými vysvětlujícími faktory se snížily pod kritickou hodnotu 0,8 až na dvě výjimky. Hodnota korelačního koeficientu CO2_SAS_{t+7} a CH4_SAS_{t+7} je 0,884. Korelační koeficient vzájemné závislosti s_MEAN_{t+7} a CH4_SAS_{t+7} je 0,808. Vytvářet model, kde vysvětlovanou proměnnou bude tento index a vysvětlujícími proměnnými dané faktory, se jeví stále jako nevýznamné.

Tabulka 4.4 Korelační koeficienty pro časově upravené proměnné

	CO2_SAS _{t+7}	CH4_SAS _{t+7}	s_MEAN _{t+7}	RE_SAS _{t+2}
CE_LINT	-0,396**	-0,244**	-0,325**	-0,261*

Zdroj: vlastní zpracování

4.4 Odhad jednofaktorových regresních modelů

V následující podkapitole budou postupně vytvořeny jednofaktorové modely pro jednotlivé indexy, celkem tedy bude sestaveno dvanáct modelů. Vysvětlovanou proměnnou bude vždy akciový index. V případě Clean Energy Indexu bude použita časová řada s nahrazenými extrémními hodnotami a časové řady nezávislých proměnných budou náležitě upraveny dle zjištění z analýzy křížové korelace. Vysvětlující proměnnou bude vždy jeden faktor. V případě faktorů CO2_SAS, CH4_SAS a RE_SAS budou použity sezónně očištěné časové řady, u proměnné s_MEAN byly použita data bez extrémní hodnoty. Pro jednofaktorové modely indexu Clean Energy byla použita časově posunutá data dle výsledků křížové korelace v kapitole 4.3.3.

S&P Global Water Index

$$W_t = -32242,992 + 88,158 \cdot \text{CO2_SAS}_t + \varepsilon_t \quad (4.19)$$

$$W_t = -44665,562 + 26,079 \cdot \text{CH4_SAS}_t + \varepsilon_t \quad (4.20)$$

$$W_t = 2462,709 + 50,937 \cdot \text{s_MEAN}_t + \varepsilon_t \quad (4.21)$$

$$W_t = -1515,745 + 21187,120 \cdot \text{RE_SAS}_t + \varepsilon_t \quad (4.22)$$

Čtyři rovnice odpovídají čtyřem modelům, kde závislou proměnnou je Water Index a nezávislou proměnnou jsou postupně čtyři faktory CO2_SAS, CH4_SAS, s_MEAN a RE_SAS. Hodnota regresního koeficientu u všech modelů je kladná. Pokud tedy jakýkoliv faktor vzroste o jednotku, úměrně dle tohoto koeficientu vzroste i hodnota indexu o příslušný počet bodů. Hodnota R Square pro vysvětlující faktor CO2_SAS je 0,899, což značí, že nezávislá proměnná z 89,9% vysvětluje proměnnou závislou. Toto číslo je relativně vysoké a lze předpokládat, že model funguje správně. Koeficienty R Square u dalších modelů jsou postupně 0,879; 0,698 a 0,830. Nejnižší koeficient je u modelu, kde nezávislou proměnnou je s_MEAN. Vypovídací schopnost modelu je zde pouze 69,8 %.

S&P Global Eco Index

$$E_t = -1391,072 + 3,907 \cdot \text{CO2_SAS}_t + \varepsilon_t \quad (4.23)$$

$$E_t = -1964,475 + 1,168 \cdot \text{CH4_SAS}_t + \varepsilon_t \quad (4.24)$$

$$E_t = 146,406 + 2,3 \cdot \text{s_MEAN}_t + \varepsilon_t \quad (4.25)$$

$$E_t = -32,866 + 954,976 \cdot \text{RE_SAS}_t + \varepsilon_t \quad (4.26)$$

V těchto modelech je vždy závislou proměnnou Eco Index, nezávislými proměnnými postupně faktory CO2_SAS, CH4_SAS, s_MEAN a RE_SAS. Ve všech modelech je regresní koeficient kladný, tudíž mezi indexem a vysvětlující proměnnou je vždy pozitivní vztah. Pokud tedy příslušný faktor vzroste o jednotku, vzroste také hodnota indexu. Například v modelu, kde nezávislou proměnnou je CO2_SAS, pokud hodnota CO2_SAS vzroste o jednotku, hodnota indexu vzroste o 3,907 bodů. Hodnota R Square je v modelu s proměnnou CO2_SAS 0,801, v modelu s CH4_SAS 0,801, v modelu s s_MEAN 0,646 a v modelu s proměnnou RE_SAS činí hodnota koeficientu R Square 0,766. Nejnižší koeficient je v modelu s vysvětlující proměnnou s_MEAN, stejně jako v modelech indexu Water. Nejlépe, z 80,1 %, fungují modely s proměnnými CO2_SAS a CH4_SAS.

S&P Global Clean Energy Index

$$\text{CE_LINT}_t = 4056,439 - 8,544 \cdot \text{CO2_SAS}_{t+7} + \varepsilon_t \quad (4.27)$$

$$\text{CE_LINT}_t = 3711,152 - 1,683 \cdot \text{CH4_SAS}_{t+7} + \varepsilon_t \quad (4.28)$$

$$\text{CE_LINT}_t = 689,46 - 4,808 \cdot \text{s_MEAN}_{t+7} + \varepsilon_t \quad (4.29)$$

$$\text{CE_LINT}_t = 905,453 - 1296,076 \cdot \text{RE_SAS}_{t+2} + \varepsilon_t \quad (4.30)$$

V poslední čtveřici modelů je závislou proměnnou vždy Clean Energy Index. Nezávislé proměnné CO2_SAS, CH4_SAS a s_MEAN předbíhají vysvětlovanou proměnnou o sedm období. Proměnná RE_SAS předbíhá vysvětlovanou proměnnou o dvě období. Regresní koeficienty jsou ve všech modelech záporné, tudíž oproti předchozím dvěma indexům je vztah závislé a nezávislé proměnné negativní. Pokud hodnota vybraného faktoru vzroste, hodnota Clean Energy Indexu, zpožděného o sedm, případně o dva měsíce, klesne o příslušný počet bodů dle regresního koeficientu. Největší pokles indexu vychází z modelu nezávislé proměnné RE_SAS_{t+2}. Pokud hodnota RE_SAS_{t+2} vzroste o jednotku, hodnota indexu klesne o 1296,076 bodů.

Koeficient R Square je ve všech modelech tohoto indexu velmi nízký, především v porovnání s modely předchozích indexů. V pořadí dle zapsaných rovnic jsou hodnoty R Square následující: 0,157; 0,06; 0,106 a 0,068. Model nejlépe vysvětluje vývoj indexu pouze z 15,7% v případě vysvětlující proměnné $CO2_SAS_{t+7}$.

V původních stanovených hypotézách byl předpoklad, že růst faktorů bude mít za následek i růst vybraných indexů. U Water Indexu a Eco Indexu byla tato hypotéza potvrzena pro všechny faktory. Vztah mezi nezávislou proměnnou a závislou proměnnou je ve všech modelech kladný. V modelech s vysvětlovanou proměnnou Clean Energy Index bylo v rámci křížové korelace zjištěn časový nesoulad mezi proměnnými. Vývoj indexu je oproti vývoji vysvětlujících faktorů zpožděn o sedm, případně o dvě období. V modelech tohoto indexu je vztah mezi nezávislou a závislou proměnnou negativní. Tudíž hypotéza, že vztah mezi proměnnými bude kladný, nebyla potvrzena.

4.5 Verifikace modelu

Verifikace modelu je předposlední fází ekonometrického modelování. Je rozdělena na tři části, verifikaci statistickou, ekonometrickou a ekonomickou.

4.5.1 Statistická verifikace

Tato podkapitola bude zaměřena na ověření statistické významnosti jednotlivých odhadnutých koeficientů modelu a následně na ověření statistické významnosti modelu jako celku. Statistická významnost parametrů bude testována za pomoci t-testu a celý model bude testován pomocí F-testu. Vzorce a teoretická východiska pro toto testování jsou popsány v kapitole 3.5.1. Testy byly provedeny na 5% hladině významnosti.

t-test

Při aplikaci t-testu je nutné nejprve stanovit výchozí hypotézy. Nulová hypotéza předpokládá statistickou nevýznamnost parametru. Hypotéza alternativní naopak formuluje předpoklad statistické významnosti koeficientu. Rozhodnutí o přijetí či nepřijetí nulové hypotézy bylo stanoveno na základě porovnání hodnoty vypočtené testovací statistiky a kritické hodnoty. Testovací kritérium bylo vyčísleno dle vztahu

3.15 a kritická hodnota byla stanovena pomocí aplikace Excel za použití funkce TINV. Pokud absolutní hodnota testovacího kritéria je vyšší než hodnota kritická, nulová hypotéza je zamítnuta a přijata hypotéza alternativní. Tabulky 4.5, 4.6 a 4.7 obsahují testovací statistiku t_{vyp} , kritickou hodnotu t_{krit} , rozhodnutí ohledně nulové hypotézy a výsledky testu.

Tabulka 4.5 zahrnuje hodnoty statistické verifikace pro modely, kde vysvětlovanou proměnnou je Water Index.

Tabulka 4.5 Výsledky t-testu pro proměnnou Water Index

proměnná	t_{vyp}	t_{krit}	H_0	závěr testu
CO2_SAS	30,223	1,983	zamítáme	významný
CH4_SAS	27,336	1,983	zamítáme	významný
s_MEAN	15,440	1,983	zamítáme	významný
RE_SAS	22,436	1,983	zamítáme	významný

Zdroj: vlastní zpracování

Z tabulky 4.5 je zřejmé, že všechny parametry jednofaktorových modelů jsou statisticky významné. Ve všech případech byla nulová hypotéza zamítnuta a přijata hypotéza alternativní.

V následující tabulce 4. 6. jsou znázorněny hodnoty testovacích kritérií a kritických hodnot modelů, kde závislou proměnnou je Eco Index.

Tabulka 4.6 Výsledky t-testu pro proměnnou Eco Index

proměnná	t_{vyp}	t_{krit}	H_0	závěr testu
CO2_SAS	20,349	1,983	zamítáme	významný
CH4_SAS	20,491	1,983	zamítáme	významný
s_MEAN	13,690	1,983	zamítáme	významný
RE_SAS	18,350	1,983	zamítáme	významný

Zdroj: vlastní zpracování

Pro všechny parametry platí, že hodnota t_{vyp} je vyšší než hodnota t_{krit} a tudíž nulová hypotéza je zamítnuta. Všechny parametry jsou tedy statisticky významné.

Tabulka 4. 7. je poslední tabulkou znázorňující výsledky t-testu a to pro modely, kde vysvětlovanou proměnnou je Clean energy Index.

Tabulka 4.7 Výsledky t-testu pro proměnnou Clean Energy Index

proměnná	t_{vyp}	t_{krit}	H_0	závěr testu
CO2_SAS _{t+7}	-4,228	1,985	zamítáme	významný
CH4_SAS _{t+7}	-2,471	1,985	zamítáme	významný
s_MEAN _{t+7}	-3,367	1,985	zamítáme	významný
RE_SAS _{t+2}	-2,650	1,985	zamítáme	významný

Zdroj: vlastní zpracování

Zde jsou hodnoty testovacího kritéria záporné, ovšem pro závěr testu jsou důležité absolutní hodnoty, tudíž znaménko zde nehraje roli. I zde platí, že po porovnání testovacího kritéria a kritické hodnoty je nulová hypotéza u všech parametrů zamítnuta. Výsledkem t-testu je přijetí hypotézy alternativní, a tedy potvrzení statistické významnosti všech parametrů.

F-test

F-test funguje na velmi podobných principech jako t-test ovšem slouží k ověření statistické významnosti modelu jako celku. I zde je nutné nejprve stanovit hypotézu nulovou a alternativní. Nulová hypotéza je formulována jako potvrzení statistické nevýznamnosti modelu. Hypotéza alternativní připouští statistickou významnost alespoň jednoho parametru. Testovací kritérium F_{vyp} bylo vyčísleno dle vzorce 3.18. Kritická hodnota byla stanovena pomocí aplikace Excel a funkce FINV. Následující tabulky jsou koncipovány stejně jako u předešlého t-testu.

První tabulka 4.8 vyjadřuje výsledky F-testu pro modely se závislou proměnnou Water Index.

Tabulka 4.8 Výsledky F-testu pro proměnnou Water Index

proměnná	F_{vyp}	F_{krit}	H_0	závěr testu
CO2_SAS	914,235	3,933	zamítáme	významný
CH4_SAS	746,856	3,933	zamítáme	významný
s_MEAN	238,354	3,933	zamítáme	významný
RE_SAS	503,359	3,933	zamítáme	významný

Zdroj: vlastní zpracování

Ve všech modelech je splněna podmínka pro zamítnutí nulové hypotézy a přijetí hypotézy alternativní. Pro všechny modely tedy platí, že jsou jako celek statisticky významné.

Tabulka 4.9 obsahuje výsledky F-testu pro modely závislé proměnné Eco Indexu. Závěrem testu je statistická významnost všech modelů. O statistické významnosti bylo rozhodnuto na základě zamítnuté nulové hypotézy a přijaté hypotézy alternativní.

Tabulka 4.9 Výsledky F-testu pro proměnnou Eco Index

proměnná	F_{vyp}	F_{krit}	H_0	závěr testu
CO2_SAS	415,715	3,933	zamítáme	významný
CH4_SAS	413,758	3,933	zamítáme	významný
s_MEAN	188,259	3,933	zamítáme	významný
RE_SAS	336,734	3,933	zamítáme	významný

Zdroj: vlastní zpracování

Poslední tabulka 4.10 zahrnuje výsledky F-testu pro modely s vysvětlovanou proměnnou Clean Energy Index. Jednofaktorové modely jsou sestaveny s proměnnými, které jsou příslušně časově posunuty. Pro všechny čtyři modely platí, že jsou jako celek statisticky významné.

Tabulka 4.10 Výsledky F-testu pro proměnnou Clean Energy Index

proměnná	F_{vyp}	F_{krit}	H_0	závěr testu
CO2_SAS _{t+7}	17,868	3,940	zamítáme	významný
CH4_SAS _{t+7}	6,101	3,940	zamítáme	významný
s_MEAN _{t+7}	11,333	3,940	zamítáme	významný
RE_SAS _{t+2}	7,023	3,940	zamítáme	významný

Zdroj: vlastní zpracování

4.5.2 Ekonometrická verifikace

Následující podkapitola shrnuje ekonometrickou verifikaci jednofaktorových modelů, která má za cíl ověřit předpoklady nutné pro aplikaci metod regresního modelování. Její součástí je testování autokorelace, heteroskedasticity a normality reziduální složky. Testování multikolinearity je u jednofaktorových modelů bezpředmětné. V celé kapitole je uvažováno s hladinou významnosti 5%.

Autokorelace

Pro zajištění správnosti modelu je nutné vyloučit autokorelaci, tedy vzájemnou závislost mezi jednotlivými odhadnutými hodnotami náhodné složky. Testování

autokorelace u všech jednofaktorových modelů bylo provedeno pomocí Durbin-Watsonova testu.

Tento test je zaměřen pouze na testování autokorelace prvního řádu. V případě přijetí nulové hypotézy je potvrzena statistická nevýznamnost autokorelace prvního řádu. Testovací kritérium bylo vyčísleno dle vztahu 3.21. Kritické hodnoty d_L a d_U , tedy hraniční hodnoty konfidenčního intervalu byly zjištěny ve statistických tabulkách dostupných na stránkách EUBA. Kritické hodnoty byly zjištěny pro příslušný počet pozorování a vždy pro model s jednou proměnnou. V testu je uvažováno s 5% hladinou významnosti. Výsledky testu a dílčí hodnoty jsou zaznamenány v následující tabulce 4.11. Závěry testu jsou stanoveny na základě obrázku 3.1 v kapitole 3.5.2 dle Hančlová (2012).

Tabulka 4.11 Výsledky Durbin- Watsonova testu

závislá proměnná	nezávislá proměnná	d_L	d_U	DW	H_0	závěr testu
Water Index	CO2_SAS	1,654	1,694	0,225	zamítáme	pozitivní autokorelace
	CH4_SAS			0,176	zamítáme	pozitivní autokorelace
	s_MEAN			0,613	zamítáme	pozitivní autokorelace
	RE_SAS			0,405	zamítáme	pozitivní autokorelace
Eco Index	CO2_SAS	1,654	1,694	0,172	zamítáme	pozitivní autokorelace
	CH4_SAS			0,165	zamítáme	pozitivní autokorelace
	s_MEAN			0,519	zamítáme	pozitivní autokorelace
	RE_SAS			0,327	zamítáme	pozitivní autokorelace
Clean Energy Index	CO2_SAS _{t+7}	1,645	1,687	0,085	zamítáme	pozitivní autokorelace
	CH4_SAS _{t+7}			0,085	zamítáme	pozitivní autokorelace
	s_MEAN _{t+7}			0,115	zamítáme	pozitivní autokorelace
	RE_SAS _{t+2}			0,096	zamítáme	pozitivní autokorelace

Zdroj: vlastní zpracování

Na základě Durbin- Watsonova testu autokorelace byla potvrzena pozitivní autokorelace ve všech jednofaktorových modelech. Jednotlivé zpožděné hodnoty náhodné složky se tedy navzájem ovlivňují. Závěr testu byl stanoven na základě zamítnutí nulové hypotézy.

Heteroskedasticita

Testování heteroskedasticity je zaměřeno na rozptyl reziduí v čase. Pro aplikaci modelu je žádoucí, aby tento rozptyl byl v čase konstantní. Situace, kdy rozptyl je konstantní, je nazývána homoskedasticita. Rozsáhlejší popis metodiky této problematiky je v kapitole 3.5.2.

K testování heteroskedasticity byl v této kapitole použit Whiteův test. Opět je nutné formulovat hypotézy. Nulová hypotéza předpokládá homoskedasticitu, alternativní naopak heteroskedasticitu. Testovací kritérium bylo vyčísleno dle vzorce 3.25. Kritická hodnota byla zjištěna pomocí aplikace Excel, funkce CHIINV, pro příslušný počet stupňů volnosti a na hladině významnosti 5%. Nulová hypotéza byla přijata, pokud testovací kritérium bylo nižší než kritická hodnota. Hodnoty testovacího kritéria, kritické hodnoty a závěry testu jsou znázorněny v tabulce 4.12.

Tabulka 4.12 Výsledky Whiteova testu

závislá proměnná	nezávislá proměnná	χ^2_{vyp}	χ^2_{krit}	H ₀	závěr testu
Water Index	CO2_SAS	93,496	127,689	přijímáme	homoskedasticita
	CH4_SAS	91,416		přijímáme	homoskedasticita
	s_MEAN	72,592		přijímáme	homoskedasticita
	RE_SAS	86,320		přijímáme	homoskedasticita
Eco Index	CO2_SAS	83,304	127,689	přijímáme	homoskedasticita
	CH4_SAS	83,304		přijímáme	homoskedasticita
	s_MEAN	67,184		přijímáme	homoskedasticita
	RE_SAS	79,664		přijímáme	homoskedasticita
Clean Energy Index	CO2_SAS _{t+7}	15,229	119,870	přijímáme	homoskedasticita
	CH4_SAS _{t+7}	5,820		přijímáme	homoskedasticita
	s_MEAN _{t+7}	10,282		přijímáme	homoskedasticita
	RE_SAS _{t+2}	6,596		přijímáme	homoskedasticita

Zdroj: vlastní zpracování

Dle závěru Watsonova testu byla u všech modelů vyloučena heteroskedasticita a potvrzena homoskedasticita. Ve všech modelech je tedy v čase rozptyl reziduí konstantní. Předpoklad aplikace regresního modelu, vyloučení heteroskedasticity, je tedy splněn u všech modelů a z tohoto hlediska modely fungují správně.

Normalita reziduální složky

Normalita reziduální složky bude poslední testovaný předpoklad aplikace regresního modelování v této kapitole. Normalita bude testována pomocí Kolmogorov-Smirnovova testu. Teoretická východiska aplikace tohoto modelu jsou popsána v kapitole 3.5.2.

Pro Kolmogorov-Smirnovův test je nulová hypotéza definována jako rovnost distribuční funkce rozdělení náhodného výběru a teoretické distribuční funkce očekávaného rozdělení. Hodnota D , která je nutná k výpočtu testovacího kritéria byla vyčíslena pomocí aplikace IBM SPSS. Následně bylo dopočteno testovací kritérium dle vzorce 3.23. Kritická hodnota pro danou hladinu významnosti je rovna 1,96. Test byl proveden na 5% hladině významnosti. Rozhodnutí o přijetí či nepřijetí nulové hypotézy bylo učiněno na základě porovnání testovacího kritéria a kritické hodnoty. Výsledky testu a dílčí hodnoty jsou znázorněny v tabulce 4.13.

Tabulka 4.13 Výsledky Kolmogorov-Smirnovova testu

závislá proměnná	nezávislá proměnná	D	z_{vyp}	z_{krit}	H_0	závěr testu
Water Index	CO ₂ _SAS	0,064	0,656	1,96	přijímáme	reziduální složka má normální rozdělení
	CH ₄ _SAS	0,072	0,738		přijímáme	
	s_MEAN	0,076	0,779		přijímáme	
	RE_SAS	0,046	0,471		přijímáme	
Eco Index	CO ₂ _SAS	0,072	0,738	1,96	přijímáme	reziduální složka má normální rozdělení
	CH ₄ _SAS	0,087	0,891		přijímáme	
	s_MEAN	0,068	0,697		přijímáme	
	RE_SAS	0,049	0,502		přijímáme	
Clean Energy Index	CO ₂ _SAS _{t+7}	0,147	1,455	1,96	přijímáme	reziduální složka má normální rozdělení
	CH ₄ _SAS _{t+7}	0,142	1,406		přijímáme	
	s_MEAN _{t+7}	0,103	1,020		přijímáme	
	RE_SAS _{t+2}	0,123	1,218		přijímáme	

Zdroj: vlastní zpracování

U všech jednofaktorových modelů byla přijata nulová hypotéza, což znamená potvrzení normálního rozdělení reziduální složky. Tedy tento předpoklad pro aplikaci metod ekonometrického modelování lze považovat za splněný.

4.6 Shrnutí jednofaktorových modelů

V předchozí části této práce bylo sestaveno celkem 12 jednofaktorových modelů. Vždy se jednalo o kombinaci akciového indexu jako závislé proměnné a jednoho faktoru jako proměnné nezávislé. Cílem sestavení jednofaktorových modelů bylo zjistit, zda bude potvrzena stanovená hypotéza, že vztah mezi indexem a faktorem bude vždy pozitivní. Při všech testech bylo uvažováno s hladinou významnosti 5%.

V rámci analýzy křížové korelace byl zjištěn časový nesoulad mezi indexem Clean Energy a jednotlivými faktory. Faktor CO2_SAS, CH4_SAS a s_MEAN předbíhá vývoj indexu o sedm období, proměnná RE_SAS předbíhá index pouze o dvě období. Báze tohoto indexu je tvořena společnostmi podnikajícími v energetickém průmyslu v odvětví obnovitelných zdrojů. Toto odvětví je často regulováno státem, tedy někdy nadměrná byrokracie a nutnost zajišťování různých povolení a certifikátů, může často způsobit nedostatečně rychlou reakci na aktuální situaci. Také vývoj a testování používaných technologií může být náročný a zdlouhavý proces. Tyto a další faktory mohou mít za následek zjištěné zpoždění vývoje indexu. Mezi vývojem Eco Indexu ani Water Indexu a vybranými faktory nebyl zjištěn časový nesoulad.

Nejsilnější vzájemná vazba s jednotlivými faktory byla zjištěna u Water Indexu. Naopak z korelační matice je zřejmé, že vzájemný vztah mezi faktory a indexem Clean Energy je velice slabý, a to i po zahrnutí časových nesouladů. Nejvyšší korelační koeficient -0,396 je mezi indexem a proměnnou CO2_SAS_{t+7}, což je při srovnání s ostatními korelačními koeficienty velmi nízká hodnota. Navíc vzájemný vztah je u všech nezávislých proměnných záporný, což neodpovídá prvotním předpokladům. Velmi silný vztah, vždy nad hodnotu korelačního koeficientu 0,8, vykazují jednotlivé faktory mezi sebou. Vůbec nejsilnější je vazba mezi proměnnou CO2_SAS a CH4_SAS, což bude zohledněno při sestavování vícefaktorových modelů. Z důvodu silné vzájemné vazby se všemi ostatními vysvětlujícími proměnnými bude vyloučena proměnná CO2_SAS.

Ve všech jednofaktorových modelech, kde jako závislá proměnná figuruje buď Water Index nebo Eco Index, byl koeficient R Square relativně vysoký. Nejlépe fungující model, z 89,9 %, je model závislé proměnné Water Indexu a nezávislé proměnné CO2_SAS. Z modelů, kde závislou proměnnou je Eco Index, byl nejvyšší koeficient R Square shodně 0,801 v případě nezávislých proměnných CO2_SAS a

CH4_SAS. Vypovídací schopnost jednofaktorových modelů indexu Clean Energy byla velmi nízká. Nejvyšší zjištěný koeficient R Square byl v jednofaktorovém modelu s nezávislou proměnnou $CO2_SAS_{t+7}$ a to pouze 0,157. Z důvodů nízké vypovídací schopnosti jednofaktorových modelů indexu Clean Energy, již nebude tento index použit při sestavování vícefaktorových modelů.

V rámci statistické verifikace a testování statistické významnosti pomocí t-testu a F-testu byla zjištěna statistická významnost parametrů ve všech modelech a dále potvrzena statistická významnost všech modelů jako celku.

Při testování předpokladů pro aplikaci využití metod regresní analýzy byl zjištěn pouze problém autokorelace. U všech jednofaktorových modelů byla potvrzena pozitivní autokorelace prvního řádu. Heteroskedasticita, testována pomocí Whiteova testu, byla u všech modelů vyloučena. Ve všech modelech bylo také prokázáno normální rozložení reziduální složky.

4.7 Vícefaktorové modely

Na základě výsledků jednofaktorových modelů byly vybrány proměnné pro sestavení vícefaktorových modelů. Jako závislé proměnné budou použity dva z původních tří indexů, a to Water Index a Eco Index. Jako nezávislé proměnné budou v obou modelech použity tři faktory, CH4_SAS, s_MEAN a RE_SAS. Z modelu je z výše popsaných důvodů vyloučen faktor CO2_SAS. Nejprve bude provedena korelační analýza. Následně budou sestaveny dvě rovnice vícefaktorových modelů pro dva indexy. Statistická verifikace bude opět obsahovat t-test a F-test. V rámci ekonometrické verifikace bude proveden test autokorelace, heteroskedasticity, normality reziduální složky a navíc, oproti jednofaktorovým modelům, také test multikolinearity.

Ekonometrická formulace vícefaktorových modelů je znázorněna v rovnicích 4.31 a 4.32. V první rovnici je závislou proměnnou Water Index (W) a nezávislými proměnnými CH4_SAS, s_MEAN a RE_SAS. V druhé rovnici je závislou proměnnou Eco Index (E) a nezávislými proměnnými opět CH4_SAS, s_MEAN a RE_SAS. Proměnné CH4_SAS a RE_SAS jsou očištěny od sezónních vlivů a proměnná s_MEAN je očištěna od extrémních hodnot.

$$W_t = \beta_1 + \beta_2 \cdot CH4_SAS_t + \beta_3 \cdot s_MEAN_t + \beta_4 \cdot RE_SAS_t + \varepsilon_t \quad (4.31)$$

$$E_t = \beta_1 + \beta_2 \cdot CH4_SAS_t + \beta_3 \cdot s_MEAN_t + \beta_4 \cdot RE_SAS_t + \varepsilon_t \quad (4.32)$$

4.7.1 Korelační analýza

Výstupem korelační analýzy je korelační matice, která je znázorněna v tabulce 4.14. Tabulka obsahuje korelační koeficienty, které udávají sílu vzájemné vazby mezi nezávislými a závislou proměnnou. Tabulka obsahuje vzájemné vazby mezi oběma indexy a třemi faktory. Dvě hvězdičky symbolizují statistickou významnost na 1% hladině významnosti.

Tabulka 4.14 Korelační matice

	W	E	CH4_SAS	s_MEAN	RE_SAS
W	1	0,955**	0,937**	0,836**	0,911**
E	0,955**	1	0,895**	0,804**	0,875**
CH4_SAS	0,937**	0,895**	1	0,853**	0,952**
s_MEAN	0,836**	0,804**	0,853**	1	0,832**
RE_SAS	0,911**	0,875**	0,952**	0,832**	1

Zdroj: vlastní zpracování

Všechny korelační koeficienty jsou statisticky významné na 1% hladině významnosti. Hodnota všech koeficientů je vyšší než 0,8. V případě vzájemných vazeb mezi indexy a jednotlivými faktory je vyšší hodnota vždy lepší. Ovšem korelace mezi jednotlivými nezávislými proměnnými by měla být co nejnižší. Obecné pravidlo nejčastěji uváděné v publikacích je, že hodnota korelačního koeficientu by měla být nižší než 0,8. Toto pravidlo není splněno ani u jednoho koeficientu. Vůbec nejsilnější vzájemný vztah je mezi proměnnou CH4_SAS a RE_SAS, kde hodnota koeficientu je 0,952.

4.7.2 Odhad vícefaktorových regresních modelů

Odhad vícefaktorových modelů proběhl opět v prostředí aplikace IBM SPSS. Byly vytvořeny dva vícefaktorové modely na základě rovnic 4.31 a 4.32 popsanych v úvodu kapitoly 4.7. Souhrnný výstup aplikace je součástí Přílohy 5.

$$W_t = -32092,694 + 18,691 \cdot CH4_SAS_t + 7,332 \cdot s_MEAN_t + 3980,407 \cdot RE_SAS_t + \varepsilon_t \quad (4.33)$$

$$E_t = -1252,344 + 0,749 \cdot CH4_SAS_t + 0,384 \cdot s_MEAN_t + 237,246 \cdot RE_SAS_t + \varepsilon_t \quad (4.34)$$

Koeficienty u všech nezávislých proměnných u obou modelů jsou kladné, tudíž závislou proměnnou ovlivňují pozitivně. Například, pokud hodnota proměnné CH4_SAS vzroste o jednotku, index W vzroste o 18,691 bodů a index E o 0,749 bodů, za jinak nezměněných podmínek. Takto lze interpretovat koeficienty u všech vysvětlujících proměnných. U modelu se závislou proměnnou W je hodnota R Square 0,886, což znamená, že model funguje z 88,6%. Při porovnání s jednofaktorovými modely těchto proměnných, je tato hodnota vyšší než u kteréhokoliv jednofaktorového modelu. Hodnota R Square u vícefaktorového modelu indexu E je 0,811, což lze opět interpretovat jako 81,1% správnost modelu. Hodnoty koeficientů R Square u jednofaktorových modelů byly maximálně 0,801, z čehož vyplývá, že vícefaktorový model má vyšší vypovídací schopnost.

4.7.3 Statistická verifikace

Stejně jako u jednofaktorových modelů i zde byl pro potřeby statistické verifikace použit t-test a F-test. T-test byl použit pro testování statistické významnosti jednotlivých proměnných a F-test pro testování statistické významnosti modelu jako celku.

Teoretická východiska t-testu jsou popsány v kapitole 3.5.1. Hypotézy byly formulovány dle vztahu 3.14 a statistická kritéria vyčíslena dle vztahu 3.15. Kritická hodnota byla stanovena pomocí aplikace Excel a její funkce TINV. Závěry t-testu jsou znázorněny v tabulce 4.15

Tabulka 4.15 Výsledky t-testu vícefaktorových modelů

závislá proměnná	nezávislá proměnná	t_{vyp}	t_{krit}	H_0	závěr testu
Water Index	CH4_SAS	5,704	1,983	zamítáme	významný
	s_MEAN	1,858		přijímáme	nevýznamný
	RE_SAS	1,543		přijímáme	nevýznamný
Eco Index	CH4_SAS	3,783	1,983	zamítáme	významný
	s_MEAN	1,607		přijímáme	nevýznamný
	RE_SAS	1,521		přijímáme	nevýznamný

Zdroj: vlastní zpracování

Dle závěrů t-testu je u obou modelů statisticky významná pouze proměnná CH4_SAS. Proměnné s_MEAN a RE_SAS jsou statisticky nevýznamné na 5% hladině významnosti. Pokud by byla hladina významnosti stanovena na 10%, v modelu Water Indexu by na této hladině významnosti byla statisticky významná i proměnná s_MEAN.

Teoretická východiska F-testu jsou taktéž popsána v kapitole 3.5.1. Hypotézy tohoto testu byly sestaveny dle vztahu 3.17 a testové kritérium dle vztahu 3.18. Tímto testem je testována statistická významnost modelů jako celků. Kritická hodnota byla opět stanovena pomocí funkce FINV v aplikaci Excel. Závěry F-testu obsahuje tabulka 4.16.

Tabulka 4.16 Výsledky F-testu vícefaktorových modelů

index	F_{vyp}	F_{krit}	H_0	závěr testu
W	262,410	2,695	zamítáme	významný
E	144,598	2,695	zamítáme	významný

Zdroj: vlastní zpracování

Z výsledků F-testu je zřejmé, že oba vícefaktorové modely jsou jako celek statisticky významné.

4.7.4 Ekonometrická verifikace

Součástí ekonometrické verifikace je oproti jednofaktorovým modelům také testování multikolinearity, tedy síly vzájemného vztahu mezi jednotlivými proměnnými. Dále v této kapitole bude provedeno testování autokorelace pomocí Durbin-Watsonova testu, heteroskedasticity pomocí Whiteova testu a normality reziduální složky pomocí Kolmogorov-Smirnovova testu.

Autokorelace

Autokorelace, tedy vzájemná závislost časově zpožděných hodnot jedné proměnné, bude stejně jako u jednofaktorových modelů testována pomocí Durbin-Watsonova testu. Hypotézy, výpočet testové statistiky a metody stanovení závěru testu jsou teoreticky popsány v kapitole 3.5.2. Horní (d_U) a dolní (d_L) hranice konfidenčního intervalu byly zjištěny ze statistických tabulek dostupných na stránkách EUBA. Výsledky testu jsou znázorněny v tabulce 4.17.

Tabulka 4.17 Výsledky Durbin- Watsonova testu pro vícefaktorové modely

index	d_L	d_U	DW	H_0	závěr testu
W	1,393	1,974	0,214	zamítáme	pozitivní autokorelace
E			0,199	zamítáme	pozitivní autokorelace

Zdroj: vlastní zpracování

U obou vícefaktorových modelů byla Durbin- Watsonovým testem potvrzena pozitivní autokorelace, došlo k zamítnutí nulové hypotézy a přijetí hypotézy alternativní.

Heteroskedasticita

Heteroskedasticita je jeden z předpokladů regresní analýzy, která by měla být vyloučena. K testování heteroskedasticity byl stejně jako u jednofaktorových modelů použit Whiteův test. Metodika tohoto testu je popsána v kapitole 3.5.1. Kritická hodnota byla stanovena pomocí funkce CHIINV v aplikaci Excel. Kritické hodnoty, testovací kritéria a závěry testu jsou uvedeny v tabulce 4.18.

Tabulka 4.18 Výsledky Whiteova testu pro vícefaktorové modely

index	χ^2_{vyp}	χ^2_{krit}	H_0	závěr testu
W	92,144	128,804	přijímáme	homoskedasticita
E	84,344		přijímáme	homoskedasticita

Zdroj: vlastní zpracování

Z tabulky 4.18 je zřejmé, že u obou modelů byla vyvrácena heteroskedasticita a potvrzena homoskedasticita na základě přijetí nulové hypotézy.

Normalita reziduální složky

Reziduální složka vícefaktorových modelů by měla mít normální rozdělení. Pro ověření tohoto předpokladu byl využit Kolmogorov- Smirnovův test. Teoretická

východiska a postup testu jsou popsány v kapitole 3.5.1. Dílčí hodnoty a závěr testu pro oba modely jsou znázorněny v tabulce 4.19.

Tabulka 4.19 Výsledky Kolmogorov- Smirnovova testu pro vícefaktorové modely

index	D	z_{vyp}	z_{krit}	H_0	závěr testu
W	0,051	0,523	1,96	přijímáme	reziduální složka má normální rozdělení
E	0,065	0,666		přijímáme	

Zdroj: vlastní zpracování

U obou modelů bylo potvrzeno normální rozdělení reziduální složky, přijetím nulové hypotézy. Tento předpoklad aplikace ekonometrického modelování lze považovat za splněný.

Multikolinearita

U jednofaktorových modelů je testování multikolinearity bezpředmětné, jelikož modely obsahují pouze jednu vysvětlující proměnnou. Vícefaktorové modely již obsahují více vysvětlujících proměnných. Pro správné fungování takového modelu je žádoucí, aby míra vzájemné závislosti mezi jednotlivými vysvětlujícími proměnnými byla co nejmenší. Pokud v modelu existuje vzájemná vazba, pak v modelu existuje multikolinearita. Pro testování multikolinearity je nejprve vytvořena korelační matice proměnných CH4_SAS, s_MEAN a RE_SAS, následně je ještě proveden F-test. Teoretická východiska této problematiky jsou v kapitole 3.5.1. Korelační matice je znázorněna tabulkou 4.20. Výsledky F-testu jsou pak v tabulce 4.21.

Tabulka 4.20 Korelační matice

	CH4_SAS	s_MEAN	RE_SAS
CH4_SAS	1	0,853**	0,952**
s_MEAN	0,853**	1	0,832**
RE_SAS	0,952**	0,832**	1

Zdroj: vlastní zpracování

Z korelační matice je zřejmé, že existuje silná vzájemná korelace mezi jednotlivými proměnnými. Korelační koeficienty jsou ve všech případech vyšší než 0,8, což značí multikolinearitu, která bude ještě dále testována pomocí F-testu. Všechny koeficienty jsou statisticky významné na hladině významnosti 5%.

V rámci statistického testu je nejprve nutné formulovat hypotézy. Nulová hypotéza charakterizuje situaci, kdy vzájemná závislost mezi nezávislými proměnnými

je nevýznamná. Hypotéza alternativní je naopak formulována jako významná závislost mezi proměnnými. Testovací kritéria byly vyčísleny dle vzorce 3.27. Kritická hodnota byla zjištěna pomocí funkce FINV aplikace Excel.

Tabulka 4.21 Výsledky F-test v rámci testování multikolinearity

korelační koeficient	F_{vyp}	F_{krit}	H_0	závěr testu
0,952	325,651	2,695	zamítáme	multikolinearita
0,853	89,930		zamítáme	multikolinearita
0,832	75,720		zamítáme	multikolinearita

Zdroj: vlastní zpracování

Provedení F-testu potvrdilo významnou multikolinearitu v modelech. U všech testovaných korelačních koeficientů došlo k zamítnutí nulové hypotézy a potvrzení významné závislosti daných vysvětlujících proměnných.

4.8 Vícefaktorové modely s transformovanými proměnnými

Z důvodu nesplnění některých zásadních předpokladů pro dobré fungování regresních modelů a prokázání statistické nevýznamnosti některých nezávislých proměnných u předchozích vícefaktorových modelů popsanych v kapitole 4.7, budou v této kapitole sestaveny vícefaktorové modely s transformovanými proměnnými. Jako závislé proměnné budou opět fungovat Water a Eco Index, nezávislé proměnné budou představovat transformované hodnoty CH4_SAS, s_MEAN a RE_SAS.

V kapitole 3.3 jsou popsány tři způsoby transformace časových řad. Proměnné použité v předchozích vícefaktorových modelech byly postupně transformovány všemi způsoby, tedy pomocí difference (dle rovnice 3.5), pomocí přirozeného logaritmu (dle rovnice 3.6) a s využitím relativních přírůstků (dle rovnice 3.7). Za využití lineární regresní analýzy byly postupně sestaveny vícefaktorové modely s transformovanými proměnnými pomocí difference, přirozeného logaritmu i relativních přírůstků. Pouze vícefaktorové modely sestaveny z přirozených logaritmů proměnných mají lepší vypovídací schopnost než již sestavené modely s neupravenými proměnnými. V následujících modelech tedy bude uvažováno se závislými proměnnými ln_W a ln_E. Jako nezávislé proměnné budou použity ln_CH4_SAS, ln_s_MEAN a ln_RE_SAS.

Ekonometrická formulace vícefaktorových modelů s transformovanými hodnotami je znázorněna rovnicemi 4.35 a 4.36.

$$\ln W_t = \beta_1 + \beta_2 \cdot \ln CH4_SAS_t + \beta_3 \cdot \ln s_MEAN_t + \beta_4 \cdot \ln RE_SAS_t + \varepsilon_t \quad (4.35)$$

$$\ln E_t = \beta_1 + \beta_2 \cdot \ln CH4_SAS_t + \beta_3 \cdot \ln s_MEAN_t + \beta_4 \cdot \ln RE_SAS_t + \varepsilon_t \quad (4.36)$$

4.8.1 Korelační analýza

Korelační matice, vytvořena v rámci korelační analýzy, je znázorněna v tabulce 4.22. Tabulka obsahuje korelační koeficienty, které udávají sílu vzájemné korelace mezi jednotlivými proměnnými. Tabulka obsahuje vzájemné vazby mezi závislými i nezávislými proměnnými. Žádoucí je vždy co nejvyšší korelační koeficient mezi závislou a nezávislou proměnnou a co nejnižší hodnota koeficientu korelace mezi nezávislými proměnnými.

Tabulka 4.22 Korelační matice

	ln_W	ln_E	ln_CH4_SAS	ln_s_MEAN	ln_RE_SAS
ln_W	1	0,951**	0,928**	0,875**	0,899**
ln_E	0,951**	1	0,890**	0,747**	0,848**
ln_CH4_SAS	0,928**	0,890**	1	0,856**	0,953**
ln_s_MEAN	0,875**	0,747**	0,856**	1	0,863**
ln_RE_SAS	0,899**	0,848**	0,953**	0,863**	1

Zdroj: vlastní zpracování

Všechny korelační koeficienty jsou statisticky významné na 1% hladině významnosti. Hodnota všech koeficientů, charakterizující vztah dvou nezávislých proměnných je vyšší než 0,8, což značí problém multikolinearity, která bude později testována. V případě vzájemných vazeb mezi indexy a jednotlivými faktory je korelační koeficient také vždy vysoký. Vůbec nejsilnější vzájemný vztah je mezi proměnnou ln_CH4_SAS a ln_RE_SAS, kde hodnota koeficientu je 0,953. Stejná situace nastala i v případě netransformovaných proměnných.

4.8.2 Odhad vícefaktorových regresních modelů

Pro odhad vícefaktorových modelů byla použita aplikace IBM SPSS. Opět byly vytvořeny dva vícefaktorové modely na základě rovnic 4.35 a 4.36. Kompletní výstup získaný v aplikaci SPSS je v Příloze 5.

$$\ln_W_t = -76,761 + 11,27 \cdot \ln_CH4_SAS_t + 0,06 \cdot \ln_s_MEAN_t + 0,01 \cdot \ln_RE_SAS_t + \varepsilon_t \quad (4.37)$$

$$\ln_E_t = -88,781 + 12,513 \cdot \ln_CH4_SAS_t - 0,01 \cdot \ln_s_MEAN_t + 0,035 \cdot \ln_RE_SAS_t + \varepsilon_t \quad (4.38)$$

Koeficienty u všech nezávislých proměnných, až na jednu výjimku, u obou modelů jsou kladné, tudíž závislou proměnnou ovlivňují pozitivně. Koeficient v druhém modelu u proměnné \ln_s_MEAN je záporný, tudíž pokud hodnota \ln_s_MEAN vzroste o jednotku, hodnota \ln_E se sníží 0,01, za předpokladu, že ostatní nezávislé proměnné se nezmění. U modelu se závislou proměnnou \ln_W je hodnota R Square 0,885, což znamená, že model funguje z 88,5%. Což je téměř totožná hodnota jako u modelů s netransformovanými hodnotami. Hodnota R Square u vícefaktorového modelu indexu E je 0,792, což lze opět interpretovat jako 79,2% správnost modelu. Oproti předchozímu vícefaktorovému modelu bez transformace hodnot jde o nepatrný pokles.

4.8.3 Statistická verifikace

Součástí statistické verifikace je jako obvykle t-test a F-test. T-test byl použit pro testování statistické významnosti jednotlivých proměnných a F-test pro testování statistické významnosti modelu jako celku. Testy byly provedeny na 5% hladině významnosti

Metodika t-testu je popsána v kapitole 3.5.1. Hypotézy byly stanoveny na základě vztahu 3.14. Statistická kritéria byly vyčísleny dle vztahu 3.15. Kritická hodnota byla stanovena pomocí funkce TINV v prostředí aplikace Excel. Závěry t-testu jsou shrnuty v tabulce 4.23

Tabulka 4.23 Výsledky t-testu vícefaktorových modelů

závislá proměnná	nezávislá proměnná	t_{vyp}	t_{krit}	H_0	závěr testu
Water Index	ln_CH4_SAS	5,794	1,983	zamítáme	významný
	ln_s_MEAN	4,286		zamítáme	významný
	ln_RE_SAS	0,050		přijímáme	nevýznamný
Eco Index	ln_CH4_SAS	5,953	1,983	zamítáme	významný
	ln_s_MEAN	-0,667		přijímáme	nevýznamný
	ln_RE_SAS	0,163		přijímáme	nevýznamný

Zdroj: vlastní zpracování

Dle tabulky 4.23 u vícefaktorového modelu závislé proměnné ln_W jsou statisticky významné nezávislé proměnné ln_CH4_SAS a ln_s_MEAN. Oproti modelu s netransformovanými hodnotami má tento model o jednu významnou proměnnou více. Ve vícefaktorovém modelu závislé proměnné ln_E je statisticky významná pouze proměnná ln_CH4_SAS, což je stejná situace jako v kapitole 4.7.

Metodika F-testu je taktéž popsána v kapitole 3.5.1. Hypotézy byly formulovány na základě vztahu 3.17 a testové kritérium bylo vyčísleno dle vztahu 3.18. Kritická hodnota byla opět stanovena pomocí funkce FINV v aplikaci Excel. Závěry F-testu shrnuje tabulka 4.24.

Tabulka 4.24 Výsledky F-testu vícefaktorových modelů

index	F_{vyp}	F_{krit}	H_0	závěr testu
W	258,923	2,695	zamítáme	významný
E	128,401	2,695	zamítáme	významný

Zdroj: vlastní zpracování

Pomocí F-testu bylo dokázáno, že oba modely jsou jako celek statisticky významné.

4.8.4 Ekonometrická verifikace

Součástí ekonometrické verifikace bude testování autokorelace, heteroskedasticity, normality reziduální složky a multikolinearity. K testování budou použity stejné testy, jako tomu bylo v kapitole 4.7.

Autokorelace

Autokorelace bude testována pomocí Durbin-Watsonova testu. Metodika testu, formulace hypotéz a výpočet testovacího kritéria je popsán v kapitole 3.5.2. Kritické hodnoty, tedy horní (d_U) a dolní (d_L) hranice konfidenčního intervalu byly zjištěny ze statistických tabulek dostupných na stránkách EUBA. Výsledky testu jsou znázorněny v tabulce 4.25.

Tabulka 4.25 Výsledky Durbin- Watsonova testu pro vícefaktorové modely

index	d_L	d_U	DW	H_0	závěr testu
ln_W	1,393	1,974	0,280	zamítáme	pozitivní autokorelace
ln_E			0,172	zamítáme	pozitivní autokorelace

Zdroj: vlastní zpracování

U obou vícefaktorových modelů byla potvrzena pozitivní autokorelace, tudíž zpožděné hodnoty reziduální složky jsou navzájem na sobě závislé. V obou případech došlo k zamítnutí nulové hypotézy a přijetí hypotézy alternativní.

Heteroskedasticita

K testování heteroskedasticity byl stejně jako v předchozích případech použit Whiteův test. Metodika tohoto testu je popsána v kapitole 3.5.1. Hypotézy byly formulovány na základě vztahu 3.24 a testové kritérium bylo vyčísleno dle vztahu 3.25. Kritická hodnota byla stanovena pomocí funkce CHIINV v aplikaci Excel. Kritické hodnoty, testovací kritéria a závěry testu jsou znázorněny v tabulce 4.26.

Tabulka 4.26 Výsledky Whiteova testu pro vícefaktorové modely

index	χ^2_{vyp}	χ^2_{krit}	H_0	závěr testu
ln_W	92,040	128,804	přijímáme	homoskedasticita
ln_E	82,368		přijímáme	homoskedasticita

Zdroj: vlastní zpracování

Ze závěrů Whiteova testu lze potvrdit homoskedasticitu u obou modelů. Vždy byla přijata nulová hypotéza.

Normalita reziduální složky

K ověření předpokladu, že reziduální složka má normální rozložení, byl využit Kolmogorov- Smirnovův test. Teoretická východiska, nulová i alternativní hypotéza a

výpočet testovacího kritéria jsou popsány v kapitole 3.5.1. V tabulce 4.27. jsou znázorněny výsledky testu.

Tabulka 4.27 Výsledky Kolmogorov- Smirnovova testu pro vícefaktorové modely

index	D	z_{vyp}	z_{krit}	H_0	závěr testu
ln_W	0,071	0,728	1,96	přijímáme	reziduální složka má normální rozdělení
ln_E	0,094	0,963		přijímáme	

Zdroj: vlastní zpracování

U obou modelů byla přijata nulová hypotéza, a tedy potvrzen předpoklad, že rozdělení reziduální složky odpovídá normálnímu rozdělení.

Multikolinearita

Jelikož se jedná o vícefaktorové modely, je nutné zde otestovat i multikolinearitu. Pro správné fungování takového modelu je žádoucí, aby míra vzájemné závislosti mezi jednotlivými vysvětlujícími proměnnými byla co nejmenší. První stupeň testování je vytvoření korelační matice proměnných ln_CH4_SAS, ln_s_MEAN a ln_RE_SAS a analýza korelačních koeficientů. Druhým stupněm je provedení F-testu u hodnot, které naznačují přítomnost multikolinearity. Metodika této problematiky je popsána v kapitole 3.5.1. Korelační matice je vyjádřena tabulkou 4.28 a závěry F-testu jsou pak v tabulce 4.29.

Tabulka 4.28 Korelační matice

	ln_CH4_SAS	ln_s_MEAN	ln_RE_SAS
ln_CH4_SAS	1	0,856**	0,953**
ln_s_MEAN	0,856**	1	0,863**
ln_RE_SAS	0,953**	0,863**	1

Zdroj: vlastní zpracování

Z korelační matice vyplývá, že existuje silná vzájemná korelace mezi transformovanými hodnotami jednotlivých proměnných. Korelační koeficienty jsou nepatrně vyšší než u netransformovaných hodnot. Jelikož všechny koeficienty značí problém multikolinearity, bude u všech ještě proveden F-test. Všechny koeficienty jsou statisticky významné na hladině významnosti 5%.

Prvním krokem v aplikaci F-testu je formulování nulové a alternativní hypotézy. Nulová hypotéza je formulována jako nevýznamná závislost dvou proměnných. Hypotéza alternativní je naopak formulována jako významná závislost mezi

proměnnými. Testovací kritéria byly vyčísleny dle vzorce 3.27. Kritická hodnota byla zjištěna pomocí funkce FINV aplikace Excel.

Tabulka 4.29 Výsledky F-test v rámci testování multikolinearity

korelační koeficient	F_{vyp}	F_{krit}	H_0	závěr testu
0,953	333,109	2,695	zamítáme	multikolinearita
0,863	98,240		zamítáme	multikolinearita
0,856	92,301		zamítáme	multikolinearita

Zdroj: vlastní zpracování

Provedení F-testu potvrdilo významnou multikolinearitu v případě vzájemných vztahů všech tří proměnných. U všech testovaných korelačních koeficientů došlo k zamítnutí nulové hypotézy, a tedy potvrzení významné korelace.

4.9 Závěrečný vícefaktorový model

Dle výsledků odhadnutých modelů regresní analýzy s transformovanými proměnnými byl odhadnut poslední vícefaktorový model. V modelu je jako závislá proměnná transformovaná hodnota \ln_W . Jako nezávislé proměnné jsou použity transformované hodnoty faktorů \ln_CH4_SAS a \ln_s_MEAN . Postup pro odhad regresního modelu byl stejný jako v předchozích případech, pro potřeby práce byly v této podkapitole zaznamenány jen relevantní informace.

Rovnice 4.39 znázorňuje odhadnutý vícefaktorový model. V tabulce 4.30 jsou zaznamenány výsledky statistické a ekonometrické analýzy.

$$\ln_W_t = -77,379 + 11,35 \cdot \ln_CH4_SAS_t + 0,06 \cdot \ln_s_MEAN_t + \varepsilon_t \quad (4.39)$$

Z rovnice je patrné, že obě nezávislé proměnné mají kladný vztah se závislou proměnnou. Pokud hodnota proměnné \ln_CH4_SAS vzroste o jednotku, hodnota \ln_W vzroste o 11,35 bodů, za jinak neměnných podmínek. Obdobně lze interpretovat koeficient u proměnné \ln_s_MEAN . Hodnota R Square je 0,885, což značí, že model funguje z 88,5%. Jde o stejnou hodnotu koeficientu jako u modelu \ln_W i s proměnnou \ln_RE_SAS . Odstranění nevýznamné proměnné nezvýšilo vypovídací schopnost odhadnutého modelu.

Pro analýzu korelačních koeficientů lze využít korelační matici 4.22. Korelační koeficienty mezi nezávislými proměnnými jsou vysoké a lze tedy předpokládat problém

multikolinearity. Vysoké jsou také koeficienty mezi závislou a nezávislými proměnnými, což je žádoucí pro správné fungování modelu.

Tabulka 4.30 Shrnutí závěrečného vícefaktorového modelu

test	testovací kritérium	kritická hodnota	H_0	závěr testu
t- test (ln_CH4_SAS)	10,290	1,983	zamítáme	statisticky významný
t- test (ln_s_MEAN)	4,615		zamítáme	statisticky významný
F-test	392,230	3,085	zamítáme	statisticky významný
D-W test	0,28	(1,613; 1,736)	zamítáme	pozitivní autokorelace
Whiteův test	92,04	128,804	přijímáme	homoskedasticita
K-S test	0,717	1,96	přijímáme	normalita reziduální složky
Multikolinearita	139,823	3,085	zamítáme	multikolinearita

Zdroj: vlastní zpracování

Provedením t-testu byla potvrzena statistická významnost obou proměnných. F-test následně prokázal statistickou významnost modelu jako celku. Durbin-Watsonovým testem byla potvrzena pozitivní autokorelace, korelační analýza a následný F-test korelačního koeficientu potvrdil silnou multikolinearitu. Whiteův test potvrdil homoskedasticitu a Kolmogorov- Smirnovův test potvrdil normalitu reziduální složky. Jedná se o jediný vícefaktorový model, který obsahuje pouze statisticky významné proměnné.

4.10 Shrnutí vícefaktorových modelů

Nejprve byly sestaveny dva vícefaktorové modely s hodnotami proměnných jako v modelech jednofaktorových. U prvního modelu byla závislá proměnná Water Index a nezávislé proměnné CH4_SAS, s_MEAN a RE_SAS. V druhém modelu byla závislá proměnná Eco Index a nezávislé proměnné CH4_SAS, s_MEAN a RE_SAS.

V modelu se závislou proměnnou W, dle hodnoty R Square model fungoval z 88,6%. V modelu se závislou proměnnou E dle stejného měřítka model fungoval z 81,1%. Oba vícefaktorové modely mají vyšší vypovídací schopnost než modely jednofaktorové. U obou modelů byla v rámci statistické verifikace a t-testu potvrzena

statistická významnost pouze jedné proměnné, a to CH4_SAS. F-test potvrdil statistickou významnost modelu jako celku. V rámci ekonometrické verifikace v obou modelech byla potvrzena pozitivní autokorelace a multikolinearita ve vzájemných vztazích všech třech proměnných, která byla potvrzena také F-testem. Problém heteroskedasticity byl u obou modelů vyloučen a bylo potvrzeno normální rozložení reziduální složky.

Na základě výsledků předchozích modelů byly v kapitole 4.8 sestaveny dva vícefaktorové modely s transformovanými proměnnými. Transformace byly využity ve snaze vyloučit autokorelaci, multikolinearitu a zvýšit vypovídací schopnost modelů. Všechny proměnné byly transformovány pomocí přirozeného logaritmu. Hodnoty R Square nepatrně klesly oproti modelům bez transformací, a to na hodnotu 88,5% u modelu se závislou proměnnou \ln_W a 79,2% u modelu se závislou proměnnou \ln_E . U druhého modelu je pokles o něco větší, i přesto je správnost modelu z 79,2% vysoká. T-test prokázal opět u obou modelů statistickou významnost proměnné \ln_CH4_SAS . Navíc u modelu s proměnnou \ln_W je statisticky významná také proměnná \ln_s_MEAN . Lze tedy usuzovat, že nejlepší model by byl složen z \ln_W jako závislé proměnné a \ln_CH4_SAS a \ln_s_MEAN jako proměnných nezávislých. V rámci výsledků ekonometrické analýzy nedošlo oproti modelům s netransformovanými hodnotami k žádným změnám. Opět byla potvrzena pozitivní autokorelace a významná multikolinearita, rozložení reziduální složky odpovídá normálnímu rozložení a byla potvrzena homoskedasticita.

Poslední vícefaktorový model obsahuje pouze statisticky významné proměnné \ln_CH4_SAS a \ln_s_MEAN . Dle koeficientu R Square model funguje z 88,5%, což je stejná hodnota jako u modelu se všemi třemi nezávislými proměnnými. Odstraněním statisticky nezávislé proměnné nedošlo ke zvýšení vypovídací schopnosti modelu. Testy ekonometrické verifikace potvrdily homoskedasticitu a normalitu reziduální složky, dále pozitivní autokorelaci a multikolinearitu. Ani v tomto modelu se nepodařilo zajistit všechny předpoklady pro aplikaci regresní analýzy, tedy vyloučit autokorelaci a multikolinearitu. Veškeré testy byly prováděny na 5% hladině významnosti.

4.11 Shrnutí výsledků regresní analýzy

V aplikační části této práce byly nejprve obecně popsány vybrané indexy a faktory, které byly následně v modelech použity jako proměnné. Časové řady hodnot byly shromážděny za období leden 2011 až září 2019. Celkem se jedná o 105 hodnot. V rámci popisné statistiky byly zjišťovány hodnoty maxima a minima, dále průměr a rozptyl. Časové řady proměnných CO₂, CH₄ a *s* byly očištěny od sezónnosti. U indexu Clean Energy a faktoru *s* byly zjištěny extrémní hodnoty, které byly vhodnou metodou nahrazeny.

Z korelační analýzy vyplynulo, že mezi indexy W a E a jednotlivými faktory je velmi silný, kladný vzájemný vztah, korelační koeficient není nikdy nižší než 0,8. Velmi silný je také vzájemný vztah mezi jednotlivými faktory, což není příznivé pro odhad regresních modelů. Nejvyšší korelační koeficienty jsou u proměnné CO₂_SAS vzhledem ke všem ostatním proměnným. Vůbec nejsilnější korelace, hodnota korelačního koeficientu 0,993, byla zjištěna mezi faktory CO₂_SAS a CH₄_SAS. Vztah mezi faktory a indexem Clean Energy je vždy záporný a korelační koeficient je relativně nízký, maximálně -0,29. Korelační koeficienty, až na jedinou výjimku, jsou statisticky významné na 1% hladině významnosti. Pomocí křížové korelace a CCF grafů bylo zjišťováno, zda existuje časový nesoulad mezi zvolenou závislou a nezávislou proměnnou. Vývoj proměnných vzhledem k vývoji Water ani Eco Indexu nevykazuje časový nesoulad. Clean Energy Index je oproti proměnným CO₂_SAS, CH₄_SAS a *s*_MEAN zpožděn o sedm období, oproti proměnné RE_SAS je zpožděn o dvě období. Následně byla vytvořena nová korelační matice s časově upravenými hodnotami. Korelační koeficienty mezi Clean Energy Indexem a faktory se sice zvýšily ale nijak významně. Nejsilnější vztah byl zjištěn mezi indexem a proměnnou CO₂_SAS_{t+7}, korelační koeficient nabyl hodnoty -0,396.

V kapitole 4.4 byly odhadnuty jednofaktorové modely pomocí regresní analýzy. Jednofaktorové modely byly sestaveny vždy tak, že závislou proměnnou představoval akciový index a nezávislou vybraný faktor. V modelech vysvětlované proměnné W byly koeficienty u vysvětlujících proměnných vždy kladné. Nejlépe fungující model byl s proměnnou CO₂_SAS, kdy hodnota R Square byla 0,899. Ze čtyř modelů se závislou proměnnou E nejlépe fungovaly, z 80,1%, ty s proměnnými CO₂_SAS a CH₄_SAS. Koeficienty byly vždy kladné, tudíž růst faktorů vždy znamenal také růst indexu.

Jednofaktorové modely indexu Clean Energy byly sestaveny z proměnných příslušně časově upravených. Koeficienty u nezávislých proměnných byly vždy záporné, tudíž vztah mezi indexem a proměnnou byl vždy negativní a růst proměnné měl za následek pokles indexu. Hodnoty R Square jsou oproti předchozím modelům velmi nízké. Nejvyšší hodnota R Square 0,157 je v modelu s proměnnou $CO2_SAS_{t+7}$. U proměnných $CH4_SAS_{t+7}$ a RE_SAS_{t+2} model vysvětluje vývoj indexu pouze z 6%.

V rámci statistické verifikace byla t-testem potvrzena statistická významnost jednotlivých proměnných a F-testem také statistická významnost modelů jako celku, a to u všech sestavených jednofaktorových modelů. V rámci ekonometrické verifikace byly modely testovány v oblastech autokorelace, heteroskedasticity a normality reziduální složky. Testování multikolinearity u jednofaktorových modelů je nevýznamné. U všech jednofaktorových modelů byla Durbin- Watsonovým testem potvrzena pozitivní autokorelace. Whiteovým testem byla vyvrácena heteroskedasticita, tedy potvrzen konstantní a konečný rozptyl náhodné složky všech modelů. Pomocí Kolmogorov- Smirnovova testu byla také potvrzena normalita reziduální složky. Rozložení reziduální složky všech modelů odpovídá rozložení normálnímu.

Jednofaktorové modely se závislou proměnnou W a E odpovídají prvotním hypotézám, tudíž že mezi indexy a faktory bude ve všech případech kladný vztah. Z jednofaktorových modelů indexu CE vyplynulo, že vztah mezi indexem CE a jednotlivými faktory je záporný. V tomto případě původní hypotéza potvrzena nebyla.

V kapitole 4.7 byly sestaveny první dva vícefaktorové modely. Jako závislé proměnné byly v modelech použity Water Index a Eco Index. Clean Energy Index již nebyl použit z důvodů malé vypovídací schopnosti jednofaktorových modelů a nízkých korelačních koeficientů mezi indexem a jednotlivými faktory. Jako nezávislé proměnné byly v modelech použity proměnné $CH4_SAS$, s_MEAN a RE_SAS . Proměnná $CO2_SAS$ byla z důvodu vysoké korelace s ostatními nezávislými proměnnými vyřazena. Korelační koeficienty mezi indexy a faktory a také mezi jednotlivými faktory vzájemně byly opět vysoké, vždy nad hodnotu 0,8. Koeficienty u proměnných v rovnicích modelu jsou vždy kladné. Růst nezávislých proměnných o jednotku způsobuje také růst indexu o příslušnou hodnotu koeficientu. Model se závislou proměnnou W dle hodnoty R Square funguje z 88,6 %. Při porovnání s jednofaktorovými modely je tato hodnota nejvyšší, a tudíž vývoj indexu lépe vysvětluje model vícefaktorový. U modelu závislé proměnné E je hodnota R Square 0,811, což je opět v porovnání s

jednofaktorovými modely nejvyšší číslo. T-test, kdy se testovala statistická významnost jednotlivých koeficientů, potvrdil statistickou významnost pouze u proměnné CH4_SAS a to u obou modelů. F-test u obou vícefaktorových modelů potvrdil statistickou významnost modelu jako celku. V rámci ekonometrické verifikace byla potvrzena pozitivní autokorelace a multikolinearita, což snižuje vypovídací schopnost modelů. Homoskedasticita a normální rozložení reziduální složky, jako předpoklady regresní analýzy, byly potvrzeny.

V kapitole 4.8 byly odhadnuty dva vícefaktorové modely s transformovanými proměnnými. K transformaci proměnných byla použita metoda přirozeného logaritmu. V prvním modelu byla závislou proměnnou transformovaná hodnota indexu ln_W, v druhém modelu transformovaná hodnota indexu ln_E. Nezávislé proměnné byly ln_CH4_SAS, ln_s_MEAN a ln_RE_SAS. Koeficient u proměnné ln_s_MEAN v modelu se závislou proměnnou ln_E je oproti všem ostatním záporný. Byl to jediný zjištěný negativní vztah mezi indexem E a faktory v této práci. Tato změna mohla vzniknout v důsledku vzájemného vlivu nezávislých proměnných, který je u jednofaktorových modelů vyloučen. V oblasti statistické verifikace byla potvrzena statistická významnost proměnné ln_CH4_SAS u obou modelů. V modelu indexu W byla statistická významnost potvrzena také u proměnné ln_s_MEAN. F-test potvrdil statistickou významnost modelů jako celku. Výsledky ekonometrické verifikace byly stejné jako u vícefaktorových modelů s netransformovanými proměnnými.

V kapitole 4.9 byl na základě závěrů kapitoly 4.8 odhadnut poslední vícefaktorový model. Model obsahuje pouze dvě statisticky významné proměnné ln_CH4_SAS a ln_s_MEAN. Odstraněním statisticky nevýznamné proměnné ovšem nedošlo ke zvýšení vypovídací schopnosti modelu, která je dle R Square 88,5%. Ekonometrická analýza opět potvrdila problém multikolinearity a pozitivní autokorelace. Normální rozložení náhodné složky bylo potvrzeno, stejně jako homoskedasticita.

V žádném z odhadnutých regresních modelů se nepodařilo odstranit problém multikolinearity a pozitivní autokorelace. Silná vzájemná závislost mezi jednotlivými nezávislými proměnnými byla zřejmá již v korelační matici 4.3. Ve snaze o odstranění těchto problémů byly vytvořeny transformované řady proměnných. Lepší výsledky oproti netransformovaným řadám byly zjištěny pouze u řad transformovaných pomocí logaritmu.

5 Závěr

Vznik akciových indexů spjatých s životním prostředím je výsledkem zvyšujícího se zájmu veřejnosti o životní prostředí a jeho změny. V bázích takových indexů jsou firmy vyvíjející nebo používající takové technologie, které deklarují šetrnost a zmírňování negativních dopadů na životní prostředí. V současné době lze najít na finančním trhu kromě těchto indexů, také například zelené dluhopisy, různé environmentální fondy a mnoho dalších finančních nástrojů, které těží ze zájmu investorů o ekologii a životní prostředí. Jelikož změny životního prostředí nelze ignorovat, tyto technologie představují v mnoha odvětvích budoucnost a nutný směr inovací. Již v současnosti se firmy neobejdou bez investic do nových, šetrných technologií a mnoho prostředků je vloženo do výzkumu a vývoje v environmentální oblasti.

Cílem této diplomové práce bylo zjistit, zda nástroje finančního trhu, konkrétně akciové indexy, s vazbou na životní prostředí jsou ovlivňovány změnami životního prostředí. V práci byly použity tři akciové indexy skupiny S&P Global, S&P Global Water Index, S&P Global Eco Index a S&P Global Clean Energy Index. Změny životního prostředí byly v práci charakterizovány čtyřmi zvolenými faktory. Jednalo se o hodnoty koncentrace oxidu uhličitého a metanu v atmosféře, počet prodaných elektromobilů v USA a podíl energie z obnovitelných zdrojů v zemích OECD.

Vztah mezi jednotlivými indexy a vybranými faktory byl modelován pomocí regresní analýzy, tedy odhadu regresních modelů pomocí metody nejmenších čtverců. Celkově bylo v práci odhadnuto dvanáct jednofaktorových modelů a pět vícefaktorových modelů. Odhady modelů byly vytvořeny vždy v logické návaznosti na výsledky předchozích analýz či již vytvořených odhadů regresních modelů. Časové řady hodnot indexů a faktorů byly zjištěny za období leden 2011 až září 2019 v měsíčních intervalech.

Pomocí korelační matice byla zjištěna silný, pozitivní vzájemný vztah mezi indexy S&P Global Water, S&P Global Eco a všemi faktory. Korelační koeficienty mezi indexem S&P Global Clean Energy a faktory byly záporné a relativně nízké, tudíž vztah mezi tímto indexem a faktory je negativní. U tohoto indexu bylo také zjištěno časové zpoždění o sedm, případně o dvě období oproti vybraným faktorům. Pro následné odhady byly použity časově upravené veličiny. Odhadnuté jednofaktorové

modely s indexy S&P Global Water a S&P Global Eco měly vysokou vypovídací schopnost a potvrdily vzájemný pozitivní vztah. Koeficient R Square v modelech indexu S&P Global Clean Energy byl naopak nízký. Koeficienty u nezávislých proměnných byly záporné, tudíž vztah mezi indexem a faktory je inverzní. Při odhadu vícefaktorových modelů byl zjištěn problém statistické nevýznamnosti některých proměnných. V návaznosti na tento problém, byly vytvořeny vícefaktorové modely s transformovanými proměnnými. I tyto modely však obsahovaly statisticky nevýznamné proměnné. Na závěr byl vytvořen dvoufaktorový model závislé proměnné \ln_W s nezávislými proměnnými \ln_CH4_SAS a \ln_s_MEAN , kde byla potvrzena statistická významnost obou parametrů.

Z dosažených výsledků je možno usuzovat, že ne u všech finančních instrumentů, které deklarují vztah k životnímu prostředí, lze tento vztah také dokázat. U dvou indexů však byl tento vztah potvrzen a změny životního prostředí mohou mít vliv na hodnotu těchto indexů. Jedná se ovšem jen o jednoho zástupce z této třídy aktiv a faktorů charakterizujících změny v životním prostředí je nespočet. Modely by šly rozšířit o další faktory, zaměřující se i na jiné oblasti životního prostředí.

Tato zjištění mohou pomoci investorům, při orientaci na trhu s "environmentálními" aktivy. Dle vývoje současné globální situace, význam tohoto odvětví se bude v budoucnosti jistě zvyšovat, bude se rozšiřovat škála těchto aktiv a hodnota investic do nových zelených technologií bude růst.

Seznam použité literatury

Odborná kniha

ARLT, Josef a Eva RUBLÍKOVÁ. *Analýza ekonomických časových řad s příklady*. Praha: Vysoká škola ekonomická, 2002. 147 s. ISBN 80-245-0307-7

CIPRA, Tomáš. *Finanční ekonometrie*. 2. upr. vyd. Praha: Ekopress, 2013. 538 s. ISBN 978-80-86929-93-4

HANČLOVÁ, Jana. *Ekonometrické modelování: klasické přístupy s aplikacemi*. Praha: Professional Publishing, 2012. 214 s. ISBN 978-80-7431-088-1.

HUŠEK, Roman. *Ekonometrická analýza*. Praha: Oeconomica, 2007. 367 s. ISBN 978-80-245-1300-3.

SANDOR, L. Richard, CLARK, Nathan J., KANAKASABAI, Murali a MARQUES, Rafael F. *Environmental markets: a new asset class*. The CFA Institute Research Foundation, 2014. 159 s. ISBN 978-1-934667-66-8

VESELÁ, Jitka. *Investování na kapitálových trzích*. 3. vydání. Praha: Wolters Kluwer, 2019. 950 s. ISBN 978-80-7598-212-4.

Elektronické dokumenty a ostatní

2 DEGREES INSTITUTE: *Global CH₄ Levels* [online]. THE 2° INSTITUTE. [16.11.2019]. Dostupné z: <https://www.methanelevels.org/>

2° Institute [online]. Sechelt: 2 Degrees Institute, 2020. [16.11.2019]. Dostupné z: <https://www.2degreesinstitute.org/>

Co jsou to obnovitelné zdroje energie? *E.ON Rádce* [online]. Praha. [24.11.2019] Dostupné z: <https://www.eon.cz/radce/obnovitelne-zdroje-energie>

Dow Jones Industrial Average®. *S&P Dow Jones Indices* [online]. New York: S&P Dow Jones Indices, 2020. [20.1.2020] Dostupné z: <https://us.spindices.com/indices/equity/dow-jones-industrial-average>

DURBIN-WATSON d STATISTIC: SIGNIFICANCE POINTS OF dL AND dU AT 0
[online]. [17.12.2019] Dostupné z:
<http://fhi.sk/files/katedry/kove/predmety/Ekonometria1/Durbin-Watson.pdf>

FOUSEK, Daniel. Vědecké okénko: Na cestě do historie elektromobility, díl 1. aneb jak to všechno začalo. *Elektrickévozy.cz* [online]. Praha, 2019. [17.2.2020] Dostupné z:
<https://elektrickevozy.cz/clanky/vedecke-okenko-na-cestech-do-historie-elektromobility-dil-1-aneb-jak-to-vsechno-zacalo>

FOUSEK, Daniel. Vědecké okénko: Na cestě do historie elektromobility, díl 2. aneb vývojový boom. *Elektrickévozy.cz* [online]. Praha, 2020. [17.2.2020] Dostupné z:
<https://elektrickevozy.cz/clanky/vedecke-okenko-na-cestech-do-historie-elektromobility-dil-2-aneb-vyvojovy-boom>

GANTI, AKHILESH a Gordon SCOTT. Asset Class. *Investopedia* [online]. New York: Dotdash, 2020 [13.3.2020]. Dostupné z:
<https://www.investopedia.com/terms/a/assetclasses.asp>

Global Climate Change: Vital Signs of the Planet: *Carbon Dioxide* [online]. Earth Science Communications Team. [23.1.2020] Dostupné z: <https://climate.nasa.gov/vital-signs/carbon-dioxide/>

HANČLOVÁ, Jana. Ekonometrie: Jednoduchý lineární regresní model [přednáška]. Ostrava, VŠB-TU, Ekonomická fakulta, 1.10.2019.

HTMW Team. What is the Dow Jones Industrial Average. *HowTheMarketWorks.com* [online]. Stock-Trak®. [13.3.2020] Dostupné z:
<https://education.howthemarketworks.com/what-is-the-dow-jones-industrial-average/>

KLEGER, Ladislav a Petr VÁLEK. Oxid uhličitý. *Arnika* [online]. Praha, 2014. [23.1.2020] Dostupné z: <https://arnika.org/oxid-uhlicity>

KOŤÁTKO, Lukáš. Historie obchodování na burze. *Lynx* [online]. Praha. [7.3.2020] Dostupné z: <https://www.lynxbroker.cz/vzdelavani/historie-obchodovani-na-burze/>

LOVEDAY, Steven. Editor's Update: Monthly Plug-In EV Sales Scorecard: September 2019. *INSIDEEVs* [online]. 2019. [17.2.2020] Dostupné z: <https://insideevs.com/news/373812/ev-sales-scorecard-september-2019/>

LOVEDAY, Steven. Monthly Plug-In EV Sales Scorecard: Historical Charts. *INSIDEEVs* [online]. 2018. [17.2.2020] Dostupné z: <https://insideevs.com/news/344007/monthly-plug-in-ev-sales-scorecard-historical-charts/>

Our Company. *S&P Dow Jones Indices* [online]. New York: S&P Dow Jones Indices, 2020. [20.1.2020] Dostupné z: <https://us.spindices.com/our-company/our-history/>

PRIME, Julian a Mathilde DAUGY. *Monthly electricity statistics: Revised Historical Data* [online]. Paříž: International Energy Agency, 2019. [8.10.2019] Dostupné také z: <https://www.iea.org/reports/monthly-oecd-electricity-statistics>

PRIME, Julian a Mathilde DAUGY. *Monthly electricity statistics* [online]. Paříž: International Energy Agency, 2020. [8.10.2019] Dostupné také z: <https://www.iea.org/reports/monthly-oecd-electricity-statistics>

SARAH, Loff. About NASA. *NASA* [online]. Washington, DC: National Aeronautics and Space Administration, 2019. [8.12.2019] Dostupné z: <https://www.nasa.gov/about/index.html>

S&P Global Eco Index. *S&P Dow Jones Indices LLC* [online]. 2020. [4.10.2019] Dostupné z: <https://us.spindices.com/indices/equity/sp-global-eco-index>

S&P Global Clean Energy Index. *S&P Dow Jones Indices LLC* [online]. 2020. [4.10.2019] Dostupné z: <https://us.spindices.com/indices/equity/sp-global-clean-energy-index>

S&P Global Water Index. *S&P Dow Jones Indices LLC* [online]. 2020. [4.10.2019] Dostupné z: <https://us.spindices.com/indices/equity/sp-global-water-index>

S&P Thematic Indices Methodology [online]. S&P Dow Jones Indices, 2020. [4.10.2019] Dostupné z: <file:///C:/Users/Nikola/Downloads/methodology-sp-thematic-indices.pdf>

STEINFELD, H., P. GERBER, T. WASSENAAR, C. CASTEL, M. ROSALES a C. DE HAAN. Stanovisko FAO: Hospodářská zvířata mají významný vliv na životní prostředí. *Česká společnost pro výživu a vegetariánství* [online]. 2006 [12.2.2020]. Dostupné z: <https://www.csvv.cz/index.php/vyziva/ekologie-vyzivy/stanovisko-fao/543-dlouhy-stin-kapitola-1-uvod>

Třídy aktiv. *Capital.com* [online]. Capital Com SV Investments, 2020 [4.3.2020]. Dostupné z: <https://capital.com/cs/tridy-aktiv-definice>

VÁLEK, Petr, Kamil REPEŠ a Petr VÁLEK. Methan. *Arnika* [online]. Praha, 2014. [26.1.2020] Dostupné z: <https://arnika.org/methan>

Základní informace o OECD. *Stálá mise České republiky při OECD v Paříži* [online]. Praha. [26.1.2020] Dostupné z: https://www.mzv.cz/oecd.paris/cz/zakladni_informace_o_oecd/index.html

Seznam zkratek

CE	S&P Global Clean Energy Index
CE_LINT	S&P Global Clean Energy Index bez extrémních hodnot
CFA	Chartered Analyst Program
CH ₄	metan
CH ₄ _SAS	sezónně očištěné hodnoty metanu
CME Group Inc.	Chicago Mercantile Exchange and Chicago Board of Trade
CNG	Compressed Natural Gas
CO ₂	oxid uhličitý
CO ₂ _SAS	sezonně očištěné hodnoty oxidu uhličitého
DJIA	Dow Jones Industrial Average
DJTA	Dow Jones Transportation Average
DW	Durbin- Watsonův koeficient
E	S&P Global Eco Index
EUBA	Ekonomická univerzita v Bratislavě
EV	electric vehicle
KS	Kolmogorov- Smirnovův test
kW	kilowatt
LLC	Limited liability company
MZV	Ministerstvo zahraničních věcí
NASA	National Aeronautics and Space Administration
NOAA	National Oceanic and Atmospheric Administration
NYSE	The New York Stock Exchange
OAPEC	Organization of Arab Petroleum Exporting Countries
OECD	The Organisation for Economic Co-operation and Development

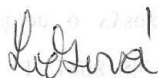
RE	podíl energie z obnovitelných zdrojů v zemích OECD
RE_SAS	sezónně očištěné hodnoty podílu energie z obnovitelných zdrojů v zemích OECD
s	objem prodeje elektromobilů a plug-in hybridů v USA
s_MEAN	hodnoty objemu prodeje elektromobilů a plug-in hybridů v USA bez extrémních hodnot
Sig.	Significant
S&P	Standard & Poor's
EUBA	Ekonomická Univerzita v Bratislavě
USA	United States of America
USD	United States Dollar
W	S&P Global Water Index

Prohlašuji, že

- jsem byla seznámena s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. – autorský zákon, zejména § 35 – užití díla v rámci občanských a náboženských obřadů, v rámci školních představení a užití díla školního a § 60 – školní dílo;
- беру на ве́доміі, že odevzdáním diplomové práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů, bez ohledu na výsledek obhajoby;
- беру на ве́доміі, že Vysoká škola báňská – Technická univerzita Ostrava (dále jen VŠB-TUO) má právo nevýdělečně, ke své vnitřní potřebě, diplomovou práci užít (§ 35 odst. 3);
- souhlasím s tím, že diplomová práce bude v elektronické podobě archivována v Ústřední knihovně VŠB-TUO. Souhlasím s tím, že bibliografické údaje o diplomové práci budou zveřejněny v informačním systému VŠB-TUO;
- bylo sjednáno, že s VŠB-TUO, v případě zájmu z její strany, uzavřu licenční smlouvu s oprávněním užít dílo v rozsahu § 12 odst. 4 autorského zákona;
- bylo sjednáno, že užít své dílo, diplomovou práci, nebo poskytnout licenci k jejímu využití mohu jen se souhlasem VŠB-TUO, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly VŠB-TUO na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Ostravě dne

24.4.2020



Bc. Nikola Ličková

Seznam příloh

Příloha 1 Vstupní data

Příloha 2 Analýza odlehlých a extrémních hodnot - box-plot grafy

Příloha 3 Korelační analýza

Příloha 4 Regresní analýza jednofaktorových modelů

Příloha 5 Regresní analýza vícefaktorových modelů






Příloha 1 Vstupní data



měsíc-rok	INDEX SP GLOBAL			nezávislé faktory			
	CE_LINT	W	E	CO2_SAS	RE_SAS	CH4_SAS	s_MEAN
1-11	1050,27	2300,608	153,708	391,0293	17,31%	1798,83	408
2-11	1101,737	2316,559	157,87	391,0624	17,65%	1797,784	348
3-11	1114,869	2304,64	159,148	391,1326	16,84%	1797,984	906
4-11	1149,16	2396,324	164,9	390,3991	16,99%	1800,812	1033
5-11	1080,388	2426,649	164,022	390,7736	17,23%	1804,069	1623
6-11	1014,235	2345,7	157,467	391,3976	18,63%	1804,452	2269
7-11	974,868	2400,23	157,85	392,1122	19,14%	1804,518	1056
8-11	820,095	2146,403	139,915	392,0316	19,20%	1805,084	1664
9-11	692,47	2082,07	135,17	392,625	19,53%	1804,106	1754
10-11	608,455	2125,897	134,467	392,4418	19,38%	1804,865	1957
11-11	576,826	2120,899	131,632	392,2396	18,92%	1806,501	1811
12-11	556,866	2091,193	129,725	392,5853	19,36%	1805,994	2563
1-12	585,55	2170,586	134,959	392,8193	19,38%	1806,23	1317
2-12	634,502	2298,37	142,735	393,0624	17,90%	1807,984	1566
3-12	597,94	2339,313	143,94	392,9326	18,14%	1808,684	3815
4-12	556,046	2332,049	142,967	393,3291	18,32%	1807,512	3565
5-12	482,971	2264,324	134,919	393,3236	18,71%	1805,769	3367
6-12	449,146	2208,137	131	393,3676	19,62%	1806,252	3124
7-12	432,421	2266,847	133,129	393,9622	19,79%	1807,718	3029
8-12	433,076	2336,082	135,378	394,2916	19,74%	1808,684	4686
9-12	437,13	2401,5	134,026	394,655	19,64%	1809,306	5745
10-12	428,849	2399,31	132,694	394,4918	19,52%	1810,165	7084
11-12	408,116	2347,648	129,868	394,9396	19,48%	1810,301	6755
12-12	449,408	2467,807	136,686	395,0653	20,09%	1809,994	8554
1-13	476,972	2565,969	141,779	395,2493	20,02%	1811,33	4577
2-13	486,046	2631,157	142,984	396,0024	19,75%	1812,284	5404
3-13	466,989	2674,65	145,334	395,9626	19,15%	1811,584	7982
4-13	498,443	2661,351	150,412	395,5591	19,68%	1811,912	7138
5-13	561,99	2740,467	159,476	396,3636	20,24%	1813,069	7454
6-13	555,457	2632,646	154,761	396,2576	20,64%	1814,152	8292
7-13	581,394	2698,077	159,207	396,9222	20,78%	1814,618	7392
8-13	591,82	2714,541	158,28	397,1016	20,45%	1813,984	11273
9-13	611,506	2786,968	159,239	396,995	20,55%	1813,206	8927
10-13	678,04	2881,895	166,042	397,1418	20,94%	1813,765	10055
11-13	674,459	2955,271	168,127	397,1196	21,12%	1814,701	9003
12-13	652,27	2976,35	166,105	397,5653	20,62%	1815,194	10010
1-14	683,228	3058,853	167,909	397,5493	20,84%	1814,53	5680
2-14	686,274	3111,111	169,358	397,2124	20,90%	1814,884	7030
3-14	720,401	3231,467	173,685	398,3026	20,57%	1816,384	9650
4-14	694,47	3221,403	172,659	398,5291	20,51%	1819,812	8895

5-14	682,706	3230,508	175,364	398,3636	20,13%	1822,969	12362
6-14	728,948	3321,954	182,229	398,9076	20,65%	1823,852	12063
7-14	733,884	3280,52	183	398,7022	21,46%	1824,118	11242
8-14	738,802	3168,41	181,093	398,9316	21,68%	1825,184	12172
9-14	728,788	3152,316	179,197	398,925	20,21%	1825,906	10921
10-14	644,305	3007,045	169,226	399,4718	20,64%	1826,265	9739
11-14	649,699	3150,357	175,031	399,2396	21,24%	1827,101	9646
12-14	623,833	3138,791	173,532	399,6353	21,28%	1828,794	13038
1-15	625,736	3112,818	174,23	399,6793	21,49%	1830,33	6057
2-15	678,261	3150,106	180,001	399,4824	20,83%	1830,784	6951
3-15	739,465	3139,166	186,555	400,0726	21,02%	1831,084	10341
4-15	795,132	3259,13	194,017	400,4291	21,44%	1832,212	9094
5-15	793,417	3292,177	191,011	400,5436	21,80%	1833,069	11540
6-15	749,951	3221,795	182,093	400,4576	21,12%	1832,952	10364
7-15	698,969	3130,524	175,109	400,9122	21,98%	1833,118	8951
8-15	638,666	3054,689	167,638	400,8316	21,68%	1834,384	8972
9-15	589,094	2918,926	159,711	401,175	21,99%	1835,306	10134
10-15	628,853	3095,733	169,502	401,7318	21,44%	1836,065	9926
11-15	606,24	3144,919	168,349	402,1196	22,76%	1838,301	10070
12-15	615,135	3085,362	168,943	402,5753	22,52%	1840,294	13699
1-16	554,049	2894,343	162,319	402,2593	22,53%	1840,03	6221
2-16	525,059	2943,403	164,115	403,3224	24,15%	1839,784	7763
3-16	574,144	3073,525	172,752	403,4026	22,82%	1840,784	13857
4-16	582,184	3187,078	175,642	404,5991	22,77%	1842,312	10531
5-16	547,95	3234,855	175,905	404,3036	22,98%	1842,869	11467
6-16	547,07	3278,163	178,475	404,4876	22,01%	1843,152	14863
7-16	572,244	3313,724	182,41	404,0122	22,50%	1842,718	13067
8-16	587,588	3359,14	183,912	404,1716	22,23%	1842,684	14592
9-16	588,672	3377,07	184,938	404,595	22,16%	1843,806	17224
10-16	569,973	3274,808	178,935	405,0318	22,13%	1844,765	11007
11-16	513,668	3201,797	173,614	405,5096	22,38%	1845,201	13237
12-16	503,673	3195,11	173,608	405,1753	22,27%	1846,394	24785
1-17	526,441	3248,762	177,386	405,8693	22,36%	1847,73	11004
2-17	547,79	3342,951	183,126	405,6624	23,59%	1847,484	12375
3-17	548,517	3416,146	188,378	405,7526	23,91%	1846,984	18542
4-17	541,349	3501,131	191,745	406,1891	23,52%	1847,512	13367
5-17	548,16	3592,903	195,936	406,2736	23,39%	1847,769	16596
6-17	543,925	3632,853	197,385	406,5376	23,86%	1848,052	17046
7-17	562,666	3642,797	198,697	406,7222	22,95%	1849,118	15540
8-17	578,41	3674,477	200,79	407,0316	23,46%	1850,984	16514
9-17	581,227	3763,327	202,57	406,915	24,39%	1852,606	21242
10-17	584,387	3859,509	203,405	406,8018	24,75%	1853,265	14315
11-17	579,159	3915,486	199,957	407,0796	23,70%	1852,901	17178
12-17	577,434	3944,976	203,096	407,5353	23,95%	1852,094	26107
1-18	614,061	4013,196	208,566	407,6593	24,51%	1852,33	12009

2-18	596,681	3806,553	200,496	407,5224	24,26%	1853,884	16845
3-18	610,516	3816,51	203,099	407,9426	25,51%	1855,584	26443
4-18	620,819	3818,645	202,252	407,3891	25,87%	1855,812	19623
5-18	626,613	3825,944	203,236	407,8136	25,05%	1855,769	24307
6-18	580,505	3774,567	198,563	408,4476	24,89%	1857,352	25029
7-18	572,866	3792,553	200,24	408,3122	23,05%	1857,718	29598
8-18	560,915	3873,42	204,861	408,8916	23,82%	1857,984	36347
9-18	548,66	3884,981	205,546	409,055	24,42%	1860,206	44544
10-18	529,406	3690,895	197,704	409,4418	24,85%	1860,865	34074
11-18	553,256	3658,613	202,858	409,9796	24,80%	1860,301	42588
12-18	547,631	3544,676	199,291	409,7953	25,02%	1861,494	49900
1-19	570,384	3641,442	206,427	410,5293	24,68%	1862,83	16715
2-19	617,201	3848,031	219,443	410,9524	25,13%	1863,484	16891
3-19	625,634	3969,236	225,066	410,5026	26,11%	1864,784	27639
4-19	643,381	4031,211	231,056	410,4691	25,87%	1864,312	21255
5-19	638,432	3950,202	229,796	411,2436	25,99%	1863,369	28386
6-19	666,446	4095,763	236,877	411,5776	26,69%	1865,552	37818
7-19	689,748	4166,844	241,561	411,3722	27,68%	1867,318	26570
8-19	692,465	4068,817	237,691	411,8516	27,76%	1868,684	27665
9-19	708,353	4188,487	240,265	412,085	28,41%	1870,306	33128

Příloha 2 Analýza odlehlých a extrémních hodnot - box-plot grafy





Příloha 3 Korelační matice

Korelační matice proměnných

Correlations								
		CE_LINT	W	E	CO2_SAS	RE_SAS	CH4_SAS	s_MEAN
CE_LINT	Pearson Correlation	1	-,121	,096	-,290**	-,281**	-,257**	-,230*
	Sig. (2-tailed)		,220	,328	,003	,004	,008	,018
	N	105	105	105	105	105	105	105
W	Pearson Correlation	-,121	1	,955**	,948**	,911**	,937**	,836**
	Sig. (2-tailed)	,220		,000	,000	,000	,000	,000
	N	105	105	105	105	105	105	105
E	Pearson Correlation	,096	,955**	1	,895**	,875**	,895**	,804**
	Sig. (2-tailed)	,328	,000		,000	,000	,000	,000
	N	105	105	105	105	105	105	105
CO2_SAS	Pearson Correlation	-,290**	,948**	,895**	1	,958**	,993**	,861**
	Sig. (2-tailed)	,003	,000	,000		,000	,000	,000
	N	105	105	105	105	105	105	105
RE_SAS	Pearson Correlation	-,281**	,911**	,875**	,958**	1	,952**	,832**
	Sig. (2-tailed)	,004	,000	,000	,000		,000	,000
	N	105	105	105	105	105	105	105
CH4_SAS	Pearson Correlation	-,257**	,937**	,895**	,993**	,952**	1	,853**
	Sig. (2-tailed)	,008	,000	,000	,000	,000		,000
	N	105	105	105	105	105	105	105
s_MEAN	Pearson Correlation	-,230*	,836**	,804**	,861**	,832**	,853**	1
	Sig. (2-tailed)	,018	,000	,000	,000	,000	,000	
	N	105	105	105	105	105	105	105
**. Correlation is significant at the 0.01 level (2-tailed).								
*. Correlation is significant at the 0.05 level (2-tailed).								





Korelační matice proměnných se zahrnutím časových nesouladů

Correlations						
		I_CE	CO2_t_7	RE_t_2	s_t_7	CH4_t_7
I_CE	Pearson Correlation	1	-,396**	-,261**	-,325**	-,244*
	Sig. (2-tailed)		,000	,009	,001	,015
	N	98	98	98	98	98
CO2_t_7	Pearson Correlation	-,396**	1	,538**	,755**	,884**
	Sig. (2-tailed)	,000		,000	,000	,000
	N	98	98	98	98	98
RE_t_2	Pearson Correlation	-,261**	,538**	1	,760**	,703**
	Sig. (2-tailed)	,009	,000		,000	,000
	N	98	98	98	98	98
s_t_7	Pearson Correlation	-,325**	,755**	,760**	1	,808**
	Sig. (2-tailed)	,001	,000	,000		,000
	N	98	98	98	98	98
CH4_t_7	Pearson Correlation	-,244*	,884**	,703**	,808**	1
	Sig. (2-tailed)	,015	,000	,000	,000	
	N	98	98	98	98	98
**. Correlation is significant at the 0.01 level (2-tailed).						
*. Correlation is significant at the 0.05 level (2-tailed).						

Korelační matice transformovaných proměnných

Correlations						
		ln W	ln E	ln CH4 SAS	ln s MEAN	ln RE SAS
ln_W	Pearson Correlation	1	,951**	,928**	,875**	,899**
	Sig. (2-tailed)		,000	,000	,000	,000
	N	105	105	105	105	105
ln_E	Pearson Correlation	,951**	1	,890**	,747**	,848**
	Sig. (2-tailed)	,000		,000	,000	,000
	N	105	105	105	105	105
ln_CH4_SAS	Pearson Correlation	,928**	,890**	1	,856**	,953**
	Sig. (2-tailed)	,000	,000		,000	,000
	N	105	105	105	105	105
ln_s_MEAN	Pearson Correlation	,875**	,747**	,856**	1	,863**
	Sig. (2-tailed)	,000	,000	,000		,000
	N	105	105	105	105	105
ln_RE_SAS	Pearson Correlation	,899**	,848**	,953**	,863**	1
	Sig. (2-tailed)	,000	,000	,000	,000	
	N	105	105	105	105	105
**. Correlation is significant at the 0.01 level (2-tailed).						

Grafy křížové korelace pro proměnnou Clean Energy Index



Příloha 4 Regresní analýza jednofaktorových modelů

Model Summary^b W=f(CO₂_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,948 ^a	,899	,898	187,418755	,225

a. Predictors: (Constant), CO₂_SAS

b. Dependent Variable: W

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	32113214,189	1	32113214,189	914,235	,000 ^b
	Residual	3617956,323	103	35125,790		
	Total	35731170,511	104			

a. Predictors: (Constant), CO₂_SAS

b. Dependent Variable: W

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-32242,992	1169,450		-27,571	,000
	CO ₂ _SAS	88,158	2,916	,948	30,236	,000

a. Dependent Variable: W

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	2173,64063	4085,42017	3112,52845	555,680579	105
Residual	-369,527344	398,218353	,000000	186,515526	105
Std. Predicted Value	-1,690	1,751	,000	1,000	105
Std. Residual	-1,972	2,125	,000	,995	105

a. Dependent Variable: W

Model Summary^b W=f(RE_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,911 ^a	,830	,828	242,749706	,405

a. Predictors: (Constant), RE_SAS

b. Dependent Variable: W

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	29661646,267	1	29661646,267	503,359	,000 ^b
	Residual	6069524,244	103	58927,420		
	Total	35731170,511	104			

a. Predictors: (Constant), RE_SAS

b. Dependent Variable: W

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-1515,745	207,647		-7,300	,000
	RE_SAS	21187,120	944,350	,911	22,436	,000

a. Dependent Variable: W

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	2052,28784	4503,71973	3112,52845	534,048815	105
Residual	-658,067932	481,487671	,000000	241,579821	105
Std. Predicted Value	-1,985	2,605	,000	1,000	105
Std. Residual	-2,711	1,983	,000	,995	105

a. Dependent Variable: W

Model Summary^b W=f(CH₄_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,937 ^a	,879	,878	205,045815	,176

a. Predictors: (Constant), CH₄_SAS

b. Dependent Variable: W

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	31400660,537	1	31400660,537	746,856	,000 ^b
	Residual	4330509,974	103	42043,786		
	Total	35731170,511	104			

a. Predictors: (Constant), CH₄_SAS

b. Dependent Variable: W

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-44665,562	1748,392		-25,547	,000
	CH ₄ _SAS	26,079	,954	,937	27,329	,000

a. Dependent Variable: W

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	2219,69922	4111,03125	3112,52845	549,481054	105
Residual	-427,105164	526,689575	,000000	204,057636	105
Std. Predicted Value	-1,625	1,817	,000	1,000	105
Std. Residual	-2,083	2,569	,000	,995	105

a. Dependent Variable: W

Model Summary^b W=f(s_MEAN)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,836 ^a	,698	,695	323,534770	,613

a. Predictors: (Constant), s_MEAN

b. Dependent Variable: W

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	24949671,522	1	24949671,522	238,354	,000 ^b
	Residual	10781498,989	103	104674,747		
	Total	35731170,511	104			

a. Predictors: (Constant), s_MEAN

b. Dependent Variable: W

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients		Sig.
		B	Std. Error	Beta	t	
1	(Constant)	2462,709	52,616		46,805	,000
	s_MEAN	50,937	3,299	,836	15,439	,000

a. Dependent Variable: W

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	2480,43506	4731,63721	3112,52845	489,796578	105
Residual	-973,391785	938,787170	,000000	321,975557	105
Std. Predicted Value	-1,291	3,306	,000	1,000	105
Std. Residual	-3,009	2,902	,000	,995	105

a. Dependent Variable: W

Model Summary^b E=f(CO₂_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,895 ^a	,801	,800	12,317011	,172

a. Predictors: (Constant), CO₂_SAS

b. Dependent Variable: E

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	63067,613	1	63067,613	415,715	,000 ^b
	Residual	15626,002	103	151,709		
	Total	78693,615	104			

a. Predictors: (Constant), CO₂_SAS

b. Dependent Variable: E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-1391,072	76,855		-18,100	,000
	CO2_SAS	3,907	,192	,895	20,389	,000

a. Dependent Variable: E

□

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	134,13840	218,86096	175,74622	24,625583	105
Residual	-22,009293	30,761604	,000000	12,257652	105
Std. Predicted Value	-1,690	1,751	,000	1,000	105
Std. Residual	-1,787	2,497	,000	,995	105

a. Dependent Variable: E

Model Summary^b E=f(RE_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,875 ^a	,766	,763	13,377492	,327

a. Predictors: (Constant), RE_SAS

b. Dependent Variable: E

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	60261,013	1	60261,013	336,734	,000 ^b
	Residual	18432,602	103	178,957		
	Total	78693,615	104			

a. Predictors: (Constant), RE_SAS

b. Dependent Variable: E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-32,866	11,443		-2,872	,005
	RE_SAS	954,976	52,041	,875	18,350	,000

a. Dependent Variable: E

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	127,95754	238,45197	175,74622	24,071411	105
Residual	-33,669533	35,554688	,000000	13,313022	105
Std. Predicted Value	-1,985	2,605	,000	1,000	105
Std. Residual	-2,517	2,658	,000	,995	105

a. Dependent Variable: E

Model Summary^b E=f(CH₄_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,895 ^a	,801	,799	12,340310	,165

a. Predictors: (Constant), CH₄_SAS

b. Dependent Variable: E

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	63008,440	1	63008,440	413,758	,000 ^b
	Residual	15685,175	103	152,283		
	Total	78693,615	104			

a. Predictors: (Constant), CH₄_SAS

b. Dependent Variable: E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients		t	Sig.
		B	Std. Error	Beta			
1	(Constant)	-1964,475	105,224			-18,670	,000
	CH ₄ _SAS	1,168	,057	,895		20,341	,000

a. Dependent Variable: E

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	135,75189	220,47420	175,74622	24,614028	105
Residual	-22,785786	25,611769	,000000	12,280838	105
Std. Predicted Value	-1,625	1,817	,000	1,000	105
Std. Residual	-1,846	2,075	,000	,995	105

a. Dependent Variable: E

Model Summary^b E=f(s_MEAN)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,804 ^a	,646	,643	16,437291	,519

a. Predictors: (Constant), s_MEAN

b. Dependent Variable: E

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	50864,609	1	50864,609	188,259	,000 ^b
	Residual	27829,006	103	270,185		
	Total	78693,615	104			

a. Predictors: (Constant), s_MEAN

b. Dependent Variable: E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	146,406	2,673		54,768	,000
	s_MEAN	2,300	,168	,804	13,721	,000

a. Dependent Variable: E

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	147,20604	248,85196	175,74622	22,115216	105
Residual	-43,305954	35,766174	,000000	16,358074	105
Std. Predicted Value	-1,291	3,306	,000	1,000	105
Std. Residual	-2,635	2,176	,000	,995	105

a. Dependent Variable: E

Model Summary^b CE_LINT=f(CO2_{t+7})

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,396 ^a	,157	,148	128,541411	,085

a. Predictors: (Constant), CO2_t_7

b. Dependent Variable: CE_LINT

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	295237,414	1	295237,414	17,868	,000 ^b
	Residual	1586197,849	96	16522,894		
	Total	1881435,263	97			

a. Predictors: (Constant), CO2_t_7

b. Dependent Variable: CE_LINT

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	4056,439	812,085		4,995	,000
	CO2	-8,544	2,021	-,396	-4,227	,000

a. Dependent Variable: CE_LINT

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	513,39594	732,64661	624,11373	55,169599	98
Residual	-242,503845	327,278625	,000000	127,877110	98
Std. Predicted Value	-2,007	1,967	,000	1,000	98
Std. Residual	-1,887	2,546	,000	,995	98

a. Dependent Variable: CE_LINT

Model Summary^b CE_LINT=f(RE_{t+2})

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,261 ^a	,068	,058	135,138286	,096

a. Predictors: (Constant), RE_t_2

b. Dependent Variable: CE_LINT

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	128249,062	1	128249,062	7,023	,009 ^b
	Residual	1753186,200	96	18262,356		
	Total	1881435,263	97			

a. Predictors: (Constant), RE_t_2

b. Dependent Variable: CE_LINT

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients		t	Sig.
		B	Std. Error	Beta			
1	(Constant)	905,453	107,039			8,459	,000
	RE_t_2	-1296,076	489,082		-,261	-2,650	,009

a. Dependent Variable: CE_LINT

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	527,12891	687,06464	624,11373	36,361453	98
Residual	-245,441528	400,712952	,000000	134,439892	98
Std. Predicted Value	-2,667	1,731	,000	1,000	98
Std. Residual	-1,816	2,965	,000	,995	98

a. Dependent Variable: CE_LINT

Model Summary^b CE_LINT=f(s_{t+7})

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,325 ^a	,106	,096	132,396938	,115

a. Predictors: (Constant), s_t_7

b. Dependent Variable: CE_LINT

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	198656,140	1	198656,140	11,333	,001 ^b
	Residual	1682779,122	96	17528,949		
	Total	1881435,263	97			

a. Predictors: (Constant), s_t_7

b. Dependent Variable: CE_LINT

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	689,460	23,572		29,249	,000
	pi_t_7	-4,808	1,428	-,325	-3,366	,001

a. Dependent Variable: CE_LINT

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	475,28333	683,12793	624,11373	45,254850	98
Residual	-241,474640	368,810547	,000000	131,712712	98
Std. Predicted Value	-3,289	1,304	,000	1,000	98
Std. Residual	-1,824	2,786	,000	,995	98

a. Dependent Variable: CE_LINT

Model Summary^b CE_LINT=f(CH4_{t+7})

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,244 ^a	,060	,050	135,746705	,085

a. Predictors: (Constant), CH4_t_7

b. Dependent Variable: CE_LINT

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	112427,154	1	112427,154	6,101	,015 ^b
	Residual	1769008,109	96	18427,168		
	Total	1881435,263	97			

a. Predictors: (Constant), CH4_t_7

b. Dependent Variable: CE_LINT

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	3711,152	1249,861		2,969	,004
	M_t_7	-1,683	,681	-,244	-2,470	,015

a. Dependent Variable: CE_LINT

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	562,94922	683,45776	624,11373	34,044718	98
Residual	-258,679291	370,575500	,000000	135,045167	98
Std. Predicted Value	-1,797	1,743	,000	1,000	98
Std. Residual	-1,906	2,730	,000	,995	98

a. Dependent Variable: CE_LINT

Příloha 5 Regresní analýza vícefaktorových modelů

Model Summary^b W=f(CH4_SAS, s_MEAN, RE_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,941 ^a	,886	,883	200,567527	,214

a. Predictors: (Constant), CH4_SAS, s_MEAN, RE_SAS

b. Dependent Variable: W

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	31668209,905	3	10556069,968	262,410	,000 ^b
	Residual	4062960,606	101	40227,333		
	Total	35731170,511	104			

a. Predictors: (Constant), CH4_SAS, s_MEAN, RE_SAS

b. Dependent Variable: W

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients		t	Sig.
		B	Std. Error	Beta			
1	(Constant)	-32092,694	5520,703			-5,813	,000
	RE_SAS	3980,407	2579,472	,171		1,543	,126
	s_MEAN	7,332	3,947	,120		1,858	,066
	CH4_SAS	18,691	3,277	,672		5,703	,000

a. Dependent Variable: W

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	2190,30811	4238,85693	3112,52845	551,817015	105
Residual	-369,502625	484,738098	,000000	197,653558	105
Std. Predicted Value	-1,671	2,041	,000	1,000	105
Std. Residual	-1,842	2,417	,000	,985	105

a. Dependent Variable: W

Model Summary^b E=f(CH4_SAS, s_MEAN, RE_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,901 ^a	,811	,806	12,130435	,199

a. Predictors: (Constant), CH4_SAS, s_MEAN, RE_SAS

b. Dependent Variable: E

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	63831,722	3	21277,241	144,598	,000 ^b
	Residual	14861,893	101	147,147		
	Total	78693,615	104			

a. Predictors: (Constant), CH4_SAS, s_MEAN, RE_SAS

b. Dependent Variable: E

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-1252,344	333,895		-3,751	,000
	RE_SAS	237,246	156,008	,217	1,521	,131
	s_MEAN	,384	,239	,134	1,608	,111
	CH4_SAS	,749	,198	,573	3,776	,000

a. Dependent Variable: E

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	133,84865	227,80202	175,74622	24,774312	105
Residual	-21,696697	28,541622	,000000	11,954197	105
Std. Predicted Value	-1,691	2,101	,000	1,000	105
Std. Residual	-1,789	2,353	,000	,985	105

a. Dependent Variable: E

Model Summary^b $\ln_W = f(\ln_CH4_SAS, \ln_s_MEAN, \ln_RE_SAS)$

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,941 ^a	,885	,882	,06717	,280

a. Predictors: (Constant), \ln_RE_SAS , \ln_s_MEAN , \ln_CH4_SAS b. Dependent Variable: \ln_W **ANOVA^a**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3,507	3	1,169	259,097	,000 ^b
	Residual	,456	101	,005		
	Total	3,963	104			

a. Dependent Variable: \ln_W b. Predictors: (Constant), \ln_RE_SAS , \ln_s_MEAN , \ln_CH4_SAS **Coefficients^a**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-76,761	14,858		-5,166	,000
	\ln_CH4_SAS	11,270	1,945	,664	5,794	,000
	\ln_s_MEAN	,060	,014	,302	4,407	,000
	\ln_RE_SAS	,010	,199	,006	,050	,960

a. Dependent Variable: \ln_W **Residuals Statistics^a**

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	7,6154	8,3400	8,0248	,18364	105
Residual	-,14233	,14782	,00000	,06620	105
Std. Predicted Value	-2,230	1,717	,000	1,000	105
Std. Residual	-2,119	2,201	,000	,985	105

a. Dependent Variable: \ln_W

Model Summary^b In_E=f(ln_CH4_SAS, ln_s_MEAN, ln_RE_SAS)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,890 ^a	,792	,786	,07258	,172

a. Predictors: (Constant), ln_RE_SAS, ln_s_MEAN, ln_CH4_SAS

b. Dependent Variable: ln_E

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2,029	3	,676	128,379	,000 ^b
	Residual	,532	101	,005		
	Total	2,561	104			

a. Dependent Variable: ln_E

b. Predictors: (Constant), ln_RE_SAS, ln_s_MEAN, ln_CH4_SAS

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients		t	Sig.
		B	Std. Error	Beta			
1	(Constant)	-88,781	16,054			-5,530	,000
	ln_CH4_SAS	12,513	2,102	,917		5,954	,000
	ln_s_MEAN	-,010	,015	-,060		-,652	,516
	ln_RE_SAS	,035	,215	,025		,161	,873

a. Dependent Variable: ln_E

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	4,9363	5,4133	5,1569	,13967	105
Residual	-,14095	,15031	,00000	,07152	105
Std. Predicted Value	-1,579	1,836	,000	1,000	105
Std. Residual	-1,942	2,071	,000	,985	105

a. Dependent Variable: ln_E

Model Summary In_W=f(ln_CH4_SAS, ln_s_MEAN)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,941 ^a	,885	,883	,06684	,280

a. Predictors: (Constant), ln_s_MEAN, ln_CH4_SAS

b. Dependent Variable: ln_W

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3,507	2	1,754	392,483	,000 ^b
	Residual	,456	102	,004		
	Total	3,963	104			

a. Dependent Variable: ln_W

b. Predictors: (Constant), ln_s_MEAN, ln_CH4_SAS

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	-77,379	8,265		-9,362	,000
	In_CH4_SAS	11,350	1,103	,668	10,286	,000
	In_s_MEAN	,060	,013	,303	4,659	,000

a. Dependent Variable: In_W

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	7,6153	8,3393	8,0248	,18364	105
Residual	-,14207	,14795	,00000	,06620	105
Std. Predicted Value	-2,230	1,712	,000	1,000	105
Std. Residual	-2,125	2,213	,000	,990	105

a. Dependent Variable: In_W